

15
ANOS

...
PESQUISAS
TIC

—
15 Years
ICT Surveys

TIC SAÚDE

Pesquisa Sobre o Uso das Tecnologias
de Informação e Comunicação nos
Estabelecimentos de Saúde Brasileiros

2019

ICT IN HEALTH

Survey on the Use of Information
and Communication Technologies
in Brazilian Healthcare Facilities

cetic.br

egi.br

Comitê Gestor da
Internet no Brasil



Atribuição Não Comercial 4.0 Internacional
Attribution NonCommercial 4.0 International



Você tem o direito de:
You are free to:



Compartilhar: copiar e redistribuir o material em qualquer suporte ou formato.
Share: copy and redistribute the material in any medium or format.



Adaptar: remixar, transformar e criar a partir do material.
Adapt: remix, transform, and build upon the material.

O licenciante não pode revogar estes direitos desde que você respeite os termos da licença.
The licensor cannot revoke these freedoms as long as you follow the license terms.

De acordo com os seguintes termos:
Under the following terms:



Atribuição: Você deve atribuir o devido crédito, fornecer um link para a licença, e indicar se foram feitas alterações. Você pode fazê-lo de qualquer forma razoável, mas não de uma forma que sugira que o licenciante o apoia ou aprova o seu uso.

Attribution: You must give appropriate credit, provide a link to the license, and indicate if changes were made. You may do so in any reasonable manner, but not in any way that suggests the licensor endorses you or your use.



Não comercial: Você não pode usar o material para fins comerciais.
Noncommercial: You may not use this work for commercial purposes.

Sem restrições adicionais: Você não pode aplicar termos jurídicos ou medidas de caráter tecnológico que restrinjam legalmente outros de fazerem algo que a licença permita.

No additional restrictions: You may not apply legal terms or technological measures that legally restrict others from doing anything the license permits.

<http://creativecommons.org/licenses/by-nc/4.0/>

Núcleo de Informação e Coordenação do Ponto BR
Brazilian Network Information Center

TIC SAÚDE

Pesquisa Sobre o Uso das Tecnologias
de Informação e Comunicação nos
Estabelecimentos de Saúde Brasileiros

2019

ICT IN HEALTH

Survey on the Use of Information
and Communication Technologies
in Brazilian Healthcare Facilities

Comitê Gestor da Internet no Brasil
Brazilian Internet Steering Committee
www.cgi.br

São Paulo
2020

Núcleo de Informação e Coordenação do Ponto BR - NIC.br

Brazilian Network Information Center - NIC.br

Diretor Presidente / CEO : Demi Getschko

Diretor Administrativo / CFO : Ricardo Narchi

Diretor de Serviços e Tecnologia / CTO : Frederico Neves

Diretor de Projetos Especiais e de Desenvolvimento / Director of Special Projects and Development : Milton Kaoru Kashiwakura

Diretor de Assessoria às Atividades do CGL.br / Chief Advisory Officer to CGL.br : Hartmut Richard Glaser

Centro Regional de Estudos para o Desenvolvimento da Sociedade da Informação - Cetic.br

Regional Center for Studies on the Development of the Information Society - Cetic.br

Coordenação Executiva e Editorial / Executive and Editorial Coordination : Alexandre F. Barbosa

Coordenação Científica / Scientific Coordination : Heimar de Fátima Marin

Coordenação de Projetos de Pesquisa / Survey Project Coordination : Fabio Senne (Coordenador / Coordinator), Ana Laura Martínez, Daniela Costa, Fabio Storino, Leonardo Melo Lins, Luciana Piazzon Barbosa Lima, Luísa Adib Dino, Luiza Carvalho e /and Manuella Maia Ribeiro

Coordenação de Métodos Quantitativos e Estatística / Statistics and Quantitative Methods Coordination : Marcelo Pitta (Coordenador / Coordinator), Camila dos Reis Lima, Isabela Bertolini Coelho, José Márcio Martins Júnior, Mayra Pizzott Rodrigues dos Santos e /and Winston Oyadomari

Coordenação de Métodos Qualitativos e Estudos Setoriais / Sectoral Studies and Qualitative Methods Coordination : Tatiana Jereissati (Coordenadora / Coordinator), Javiera F. Medina Macaya e /and Stefania Lapolla Cantoni

Coordenação de Gestão de Processos e Qualidade / Process and Quality Management Coordination : Nádilla Tsuruda (Coordenadora / Coordinator), Fabricio Torres e /and Patrycia Keico Horie

Coordenação da pesquisa TIC Saúde / ICT in Health Survey Coordination : Luciana Portilho

Gestão da pesquisa em campo / Field Management : IBOPE Inteligência Pesquisa e Consultoria Ltda, Helio Gastaldi, Rosi Rosendo, Tais Magalhães, Lígia Rubega, Ester Pereira Veloso e /and Letícia Passos

Apoio à edição / Editing support team : Comunicação NIC.br: Caroline D'Avo, Carolina Carvalho e /and Renato Soares

Preparação de Texto e Revisão em Português / Proofreading and Revision in Portuguese : Magma Editorial Ltda., Aloisio Milani, Christiane Peres, Lúcia Nascimento e / and Alexandre Pavan

Tradução para o inglês / Translation into English : Prioridade Consultoria Ltda., Grant Borowik, Isabela Ayub, Lorna Simons, Luana Guedes, Luísa Caliri e /and Maya Bellomo Johnson

Projeto Gráfico / Graphic Design : Pilar Velloso

Editoração / Publishing : Pilar Velloso e /and Polyana Achcar

Dados Internacionais de Catalogação na Publicação (CIP)

(Câmara Brasileira do Livro, SP, Brasil)

Pesquisa sobre o uso das tecnologias de informação e comunicação nos estabelecimentos de saúde brasileiros : TIC Saúde 2019 [livro eletrônico] = Survey on the use of information and communication technologies in Brazilian healthcare facilities : ICT In Health 2019 / [editor] Núcleo de Informação e Coordenação do Ponto BR. -- 1. ed. -- São Paulo : Comitê Gestor da Internet no Brasil, 2020
2569 KB ; PDF

Edição bilingue : português / inglês

Vários colaboradores

Vários tradutores

ISBN 978-65-86949-25-4

1. Internet (Rede de computadores) - Brasil 2. Saúde - Brasil 3. Tecnologia da informação e da comunicação - Brasil - Pesquisa I. Núcleo de Informação e Coordenação do Ponto BR. II. Título : Survey on the use of information and communication technologies in Brazilian healthcare facilities : ICT In Health 2019

20-46542 CDD-004.6072081

Índices para catálogo sistemático:

1. Brasil : Tecnologias da informação e da comunicação : Uso : Pesquisa 004.6072081

2. Pesquisa : Tecnologia da informação e comunicação : Uso : Brasil 004.6072081

Esta publicação está disponível também em formato digital em www.cetic.br

This publication is also available in digital format at www.cetic.br

As ideias e opiniões expressas na seção "Artigos" são dos respectivos autores e não refletem necessariamente as do NIC.br e do CGL.br.

The ideas and opinions expressed in the section of "Articles" are those of the authors. They do not necessarily reflect those of NIC.br and CGL.br.

Comitê Gestor da Internet no Brasil – CGI.br

Brazilian Internet Steering Committee – CGI.br

(em outubro de 2020/ in October, 2020)

Coordenador / Coordinator

Marcio Nobre Migon

Conselheiros / Counselors

Beatriz Costa Barbosa

Cláudio Benedito Silva Furtado

Demi Getschko

Domingos Sávio Mota

Evaldo Ferreira Vilela

Franselmo Araújo Costa

Heitor Freire de Abreu

Henrique Faulhaber Barbosa

José Alexandre Novaes Bicalho

Laura Conde Tresca

Leonardo Euler de Moraes

Luis Felipe Salin Monteiro

Marcos Dantas Loureiro

Maximiliano Salvadori Martinhão

Nivaldo Cleto

Percival Henriques de Souza Neto

Rafael de Almeida Evangelista

Rafael Henrique Rodrigues Moreira

Rosauro Leandro Baretta

Tanara Lauschner

Secretário executivo / Executive Secretary

Hartmut Richard Glaser

Agradecimentos

Apesquisa TIC Saúde 2019 contou com o apoio de uma destacada rede de especialistas, sem a qual não seria possível produzir os resultados aqui apresentados. A contribuição deste grupo se realizou por meio de discussões aprofundadas sobre os indicadores, o desenho metodológico e também a definição das diretrizes para a análise de dados. A manutenção desse espaço de debate tem sido fundamental para identificar novas áreas de investigação, aperfeiçoar os procedimentos metodológicos e viabilizar a produção de dados precisos e confiáveis. Cabe ainda ressaltar que a participação voluntária desses especialistas é motivada pela importância das novas tecnologias para a sociedade brasileira e a relevância dos indicadores produzidos pelo CGI.br para fins de políticas públicas e de pesquisas acadêmicas. Na sétima edição da pesquisa TIC Saúde, o Centro Regional de Estudos para o Desenvolvimento da Sociedade da Informação (Cetic.br) agradece aos seguintes especialistas:

Agência Nacional de Saúde Suplementar (ANS)
Celina Oliveira

Conselho Nacional de Secretarias Municipais de Saúde (CONASEMS)
Diogo Demarchi e Marizélia Leão Moreira

Departamento de Informática do SUS (Datasus)
Juliana Zinader, Mara Costa e Marcia Marinho

Empresa Brasileira de Serviços Hospitalares (EBSERH)
Claudia Brandão, Fabio Campelo e Simone Scholze

Escola Nacional de Ciências Estatísticas (ENCE)
Pedro do Nascimento Silva

Fundação Getulio Vargas (FGV)
Ana Maria Malik

Fundação Oswaldo Cruz (FIOCRUZ)
Angélica Baptista Silva

Hospital Israelita Albert Einstein
Rogéria Leoni Cruz

Hospital Sírio Libanes
Analluza Dallari e Eliane Nahas

Instituto Brasileiro de Geografia e Estatística (IBGE)
Marco Antonio Ratzsch de Andreazzi

Organização das Nações Unidas para a Educação, a Ciência e a Cultura (Unesco)
Maria Rebeca Otero Gomes

Rede Universitária de Telemedicina (Rute)
Luiz Ary Messina e Paulo Roberto de Lima Lopes

Sociedade Brasileira de Informática em Saúde (SBIS)
Beatriz de Faria Leão e Luis Gustavo Kiatake

Universidade de São Paulo (USP)
Heloisa Peres e Violeta Sun

Universidade Federal de Pernambuco (UFPE)
Magdala de Araújo Novaes

Universidade Federal de São Paulo (Unifesp)
Claudia Novoa e Ivan Torres Pisa

Universidade Federal do Amazonas (UFAM)
Tanara Lauschner

Acknowledgements

The ICT in Health 2019 survey had the support of a notable network of experts, without which it would not be possible to deliver the results presented here. This group's contribution occurred through in-depth discussions about indicators, methodological design and also the definition of guidelines for data analysis. The maintenance of this space for debate has been fundamental for identifying new areas of investigation, refining methodological procedures, and enabling the production of accurate and reliable data. It is worth emphasizing that the voluntary participation of these experts is motivated by the importance of new technologies for the Brazilian society and the relevance of the indicators produced by the CGI.br to be used in policymaking and academic research. For the 7th edition of the ICT in Health survey, the Regional Center for Studies on the Development of the Information Society (Cetic.br) would like to specially thank the following experts:

Albert Einstein Hospital
Rogéria Leoni Cruz

Brazilian Company of Hospital Services (EBSERH)
Claudia Brandão, Fabio Campelo and Simone Scholze

Brazilian Health Informatics Society (SBIS)
Beatriz de Faria Leão and Luis Gustavo Kiatake

Brazilian Institute of Geography and Statistics (IBGE)
Marco Antonio Ratzsch de Andreazzi

Federal University of Amazonas (UFAM)
Tanara Lauschner

Federal University of Pernambuco (UFPE)
Magdala de Araújo Novaes

Federal University of São Paulo (Unifesp)
Claudia Novoa and Ivan Torres Pisa

Getulio Vargas Foundation (FGV)
Ana Maria Malik

National Council of Municipal Health Secretaries (CONASEMS)
Diogo Demarchi and Marizélia Leão Moreira

National Regulatory Agency for Private Health Insurance and Plan (ANS)
Celina Oliveira

National School of Statistical Sciences (ENCE)
Pedro do Nascimento Silva

Oswaldo Cruz Foundation (FIOCRUZ)
Angélica Baptista Silva

Sírio Libanes Hospital
Analluza Dallari and Eliane Nahas

SUS Informatics Department (Datasus)
Juliana Zinader, Mara Costa and Marcia Marinho

Telemedicine University Network (Rute)
Luiz Ary Messina and Paulo Roberto de Lima Lopes

United Nations Educational, Scientific and Cultural Organization (Unesco)
Maria Rebeca Otero Gomes

University of São Paulo (USP)
Heloisa Peres and Violeta Sun

Sumário / Contents

7	Agradecimentos / Acknowledgements, 9
17	Prefácio / Foreword, 171
19	Apresentação / Presentation, 173
21	Resumo Executivo – TIC Saúde 2019
175	Executive Summary – ICT in Health 2019
29	Relatório Metodológico
183	Methodological Report
45	Relatório de Coleta de Dados
199	Data Collection Report
55	Análise dos Resultados
209	Analysis of Results
 Artigos / Articles	
99	Rede nacional de dados em saúde: experiência e interoperabilidade na rede de atenção à saúde
251	National health data network: Interoperability experience in the healthcare network <i>Jacson Venâncio de Barros, Henrique Nixon Souza da Silva, Roberta Massa Baptista, Frank James da Silva Pires e / and Juliana Pereira de Souza-Zinader</i>
113	Proteção de dados na telemedicina
265	Data protection in telemedicine <i>Analluza Bolivar Dallari</i>
125	Uso da Inteligência Artificial para otimizar o uso de dados de Registros Eletrônicos de Saúde
277	Leveraging Artificial Intelligence to maximize use of Electronic Health Record data <i>Shamim Nemat, Supreeth P. Shashikumar, Fatemeh Amrollahi, Tsung-Ting Kuo e / and Lucila Ohno-Machado</i>
143	Aprendizado de máquina em medicina cardiovascular
293	Machine learning in cardiovascular medicine <i>Marco Antonio Gutierrez e / and José Eduardo Krieger</i>
155	COVID-19: informação e decisão para adotar o lockdown
305	COVID-19: Information and decisions for adopting lockdown <i>Eduardo Massad</i>
320	Lista de Abreviaturas / List of abbreviations, 321

Lista de gráficos / Chart list

- 25 Existência de sistema eletrônico para registro das informações dos pacientes (2019)
- 179 Availability of an electronic system to record patient information (2019)
- 25 Tipo de ferramenta de segurança da informação utilizada (2019)
- 179 Type of information security tool used (2019)
- 27 Serviços de telessaúde disponíveis (2019)
- 181 Telehealth services available (2019)
- 27 UBS, por tipo de dado sobre o paciente disponível eletronicamente (2018-2019)
- 181 PHU by type of patient data electronically available (2018-2019)
- 27 UBS, por serviços oferecidos ao paciente via Internet (2019)
- 181 PHU by services offered to patients through the Internet (2019)
- 62 Estabelecimentos de saúde, por tipo de conexão à Internet (2019)
- 215 Healthcare facilities by type of Internet connection (2019)
- 63 Estabelecimentos de saúde, por faixa de velocidade máxima para *download* da principal conexão (2019)
- 216 Healthcare facilities by range of download speed of the main connection (2019)
- 65 Estabelecimentos de saúde, por principal responsável pelo suporte técnico em informática (2019)
- 218 Healthcare facilities by main person responsible for computer technical support (2019)
- 67 Estabelecimentos de saúde, por tipo de ferramenta de segurança da informação utilizada (2019)
- 220 Healthcare facilities by type of information security tool used (2019)
- 69 Estabelecimentos de saúde, por existência de sistema eletrônico para registro das informações dos pacientes (2019)
- 222 Healthcare facilities by availability of an electronic system to record patient information (2019)
- 73 Estabelecimentos de saúde, por funcionalidades eletrônicas disponíveis em sistema (2019)
- 226 Healthcare facilities by available electronic system functionalities (2019)
- 74 Estabelecimentos de saúde presentes na Internet por meio de *website* e/ou redes sociais (2019)
- 227 Healthcare facilities present on the Internet through websites and/or social networks (2019)
- 75 Estabelecimentos de saúde, por serviços oferecidos ao paciente via Internet (2019)
- 228 Healthcare facilities by services offered to patients through the Internet (2019)
- 78 Estabelecimentos de saúde, por serviços de telessaúde disponíveis (2019)
- 231 Healthcare facilities by telehealth services available (2019)
- 80 Unidades básicas de saúde, por tipo de conexão (2017 – 2019)
- 233 Primary healthcare units by type of connection (2017 – 2019)
- 81 Unidades básicas de saúde, por tipo de ferramenta de segurança da informação utilizada (2017 – 2019)
- 234 Primary healthcare units by type of information security tool used (2017 – 2019)

- 82 Unidades básicas de saúde, por forma de manutenção das informações clínicas e cadastrais nos prontuários dos pacientes (2017 – 2019)
235 Primary healthcare units by type of method used to keep patient medical records (2017 – 2019)
- 84 Unidades básicas de saúde, por tipo de dado sobre o paciente disponível eletronicamente (2017 – 2019)
236 Primary healthcare units by type of patient data available electronically (2017 – 2019)
- 85 Unidades básicas de saúde, por funcionalidades eletrônicas disponíveis em sistema (2017 – 2019)
237 Primary healthcare units by available electronic system functionality (2017 – 2019)
- 87 Médicos, por frequência de consultas aos dados sobre os pacientes disponíveis eletronicamente (2019)
239 Physicians by how often they refer to patient data electronically available (2019)
- 88 Enfermeiros, por frequência de consultas aos dados sobre os pacientes disponíveis eletronicamente (2019)
240 Nurses by how often they refer to patient data electronically available (2019)
- 89 Médicos, por frequência de uso das funcionalidades eletrônicas disponíveis em sistema (2019)
241 Physicians by how often they use the available electronic system functionalities (2019)
- 89 Enfermeiros, por frequência de uso das funcionalidades eletrônicas disponíveis em sistema (2019)
241 Nurses by how often they use the available electronic system functionalities (2019)
- 91 Médicos, por impactos percebidos em relação ao uso ou implantação de sistemas eletrônicos (2019)
243 Physicians by perceived impact of the use or implementation of electronic systems (2019)
- 92 Enfermeiros, por impactos percebidos em relação ao uso ou implantação de sistemas eletrônicos (2019)
244 Nurses by perceived impact of the use or implementation of electronic systems (2019)
- 160 Evolução do número de casos de COVID-19 a partir das projeções do modelo
310 Evolution in number of COVID-19 cases based on model projections
- 161 Evolução do número de mortes de COVID-19 a partir das projeções do modelo
311 Evolution in number of COVID-19 deaths based on model projections
- 162 Evolução da incidência diária de COVID-19 a partir das projeções do modelo
312 Evolution of daily incidence of COVID-19 based on model projections
- 163 Evolução da letalidade de COVID-19 a partir das projeções do modelo
313 Evolution of COVID-19 case fatality rate based on model projections
- 164 Número de mortes a partir do modelo, por faixa etária – projeção sem mitigação x distanciamento social
314 Number of deaths based on the model, by age interval – projections without mitigation x social distancing
- 164 Evolução da incidência diária de COVID-19 a partir do modelo
314 Evolution of daily incidence of COVID-19 based on model projections
- 165 Projeção da curva epidêmica de COVID-19 sem a adoção de *lockdown*
315 Projection of the epidemic curve of COVID-19 without the adoption of lockdown measures
- 166 Projeção de casos de COVID-19 segundo a evolução da imunidade de rebanho
316 Projection of cases of COVID-19 according to the evolution of herd immunity

Lista de tabelas / Table List

49	Alocação da amostra de estabelecimentos segundo região, localização, esfera administrativa e tipo de estabelecimento
203	Sample allocation of healthcare facilities by region, location, administrative jurisdiction and type of facility
52	Taxa de resposta de estabelecimentos segundo região, localização, esfera administrativa e tipo de estabelecimento
206	Rate of response of facilities by region, location, administrative jurisdiction and type of facility
52	Taxa de resposta de estabelecimentos para enfermeiros segundo região, localização, esfera administrativa e tipo de estabelecimento
206	Rate of response of facilities for nurses by region, location, administrative Jurisdiction, and type of facility
53	Taxa de resposta de estabelecimentos para médicos segundo região, localização, esfera administrativa e tipo de estabelecimento
207	Rate of response of facilities for physicians by region, location, administrative jurisdiction and type of facility
60	Estabelecimentos de saúde que utilizaram computador e Internet (2019)
214	Healthcare facilities that used computers and the Internet (2019)
71	Estabelecimentos de saúde, por tipo de dado sobre o paciente disponível eletronicamente (2019)
224	Healthcare facilities by type of patient data electronically available (2019)
163	Casos, óbitos e taxa de letalidade de COVID-19 – total Brasil e unidades da federação
313	Cases, deaths and case fatality rate of COVID-19 – total Brazil and states

Lista de Figuras / Figures list

25	Uso de computador e Internet nos últimos 12 meses (2019)
179	Use of computer and Internet in the last 12 months (2019)
104	Mapa mental da estratégia de saúde digital do Ministério da Saúde, com ênfase no programa Conecte SUS e no projeto da rede nacional de dados em saúde (RNDS)
256	Mental map of the digital health strategy of the ministry of health, with an emphasis on the Conecte SUS program and the National health data network project
105	Aplicativo Conecte SUS cidadão mostra os resultados dos exames realizados pelo paciente
257	Conecte SUS citizen application shows the results of tests done on a patient
106	Imagem do Conecte SUS profissional, com a visão do profissional de saúde sobre as informações do histórico do paciente
258	Image of Conecte SUS professional, providing health professionals with information from a patient's medical history
107	Ecosistema de atendimento e dados em saúde para a COVID-19
259	Care and health data ecosystem for COVID-19
108	Componentes da plataforma da RNDS
260	Components of the National health data network
129	Exemplo do algoritmo em ação
280	An illustrative example of the AISE algorithm in action
131	Diagrama esquemático do aprendizado por transferência
282	Schematic diagram of transfer learning
131	Fluxograma do <i>software</i> de previsão de sepse
282	Sepsis prediction software pipeline
134	AM clínico que protege a privacidade
285	Privacy-preserving clinical ML
156	Dinâmica da reprodutibilidade basal da infecção
306	Dynamics of the basic reproduction number of the infection
157	Estrutura de modelo S-E-I-R para a dinâmica da COVID-19
307	SEIR model structure for the COVID-19 dynamics

Prefácio

Completamos 50 anos da primeira troca de “pacotes de dados” na *Advanced Research Projects Agency Network* (Arpanet), que permitiu o advento da Internet. Passado meio século, diversas questões têm surgido motivadas pelas oportunidades e riscos trazidos pelo uso intensivo das tecnologias de informação e comunicação (TIC) na sociedade. O admirável avanço da informática ao longo desse período fundou-se na enorme expansão do poder da computação e do armazenamento e transmissão de dados. Com isso, além do surgimento de incontáveis aplicações, campos de pesquisa antigos ganharam novo fôlego, com desdobramentos nos mais diversos setores.

Destacam-se, nesse sentido, os progressos no campo da Inteligência Artificial (IA), potencializados pela disponibilidade de grandes bases de dados e pela evolução de sistemas de “aprendizado” de máquinas. Dentre os exemplos notáveis da aplicação de IA hoje, temos desde assistentes virtuais, mecanismos de busca e algoritmos de recomendação de conteúdos, presentes em grandes plataformas *on-line*, até ferramentas de reconhecimento facial, geolocalização e monitoramento epidemiológico. Se desenvolver IA não é um desafio novo, seu rápido incremento tem suscitado reflexões e levantado inúmeros debates no contexto da sociedade do conhecimento.

Ao mesmo tempo em que o uso de IA pode contribuir em grande medida para estratégias que visem ao desenvolvimento humano sustentável, ele também é objeto de atenção por parte de pesquisadores, gestores públicos, empresas e organizações da sociedade civil. Enquanto colaborador em nossas atividades, contamos com um poderoso auxiliar. No entanto, na medida em que pode atuar diretamente em decisões e deliberações, passa a afetar diversas áreas, desde políticas de *marketing* e do acesso à informação à concessão de financiamentos e aspectos da segurança pública. Os efeitos potencialmente exponenciais do uso de IA têm gerado alertas e criado preocupações fundadas frente a possíveis impactos na liberdade, privacidade e proteção de dados pessoais. Há que se considerar, ainda, a eventual majoração das brechas digitais, que podem excluir aqueles que não têm acesso à tecnologia dos potenciais benefícios no uso de IA.

Na medida em que a IA amplia a capacidade humana de apreensão da realidade e permite basear nossas decisões em volumes de dados maiores e mais consistentes, ela pode ser motor da promoção de resultados positivos em diversos campos. Como temos visto no momento complexo que vivemos, IA pode ser muito útil no combate à disseminação do novo coronavírus. Reforça-se, entretanto, que a implementação dessas práticas deve vir sempre acompanhada de uma dimensão ética, para além das questões técnicas usualmente consideradas.

Nesse sentido, o modelo multissetorial de governança protagonizado pelo Comitê Gestor da Internet no Brasil (CGI.br) pode ser inspirador para o engajamento dos diversos atores da sociedade nessa discussão, tanto para a constituição de princípios éticos no desenvolvimento de IA quanto para a recomendação de boas práticas na criação de aplicações transparentes e confiáveis. Bem configurada e utilizada, a IA pode contribuir na atenuação das desigualdades.

O Núcleo de Informação e Coordenação do Ponto BR (NIC.br) mantém seu propósito de, a partir dos recursos advindos da gestão do registro de domínios .br, atuar na efetivação de projetos que apoiam o desenvolvimento da Internet no país. Além das iniciativas em infraestrutura, como a implementação e operação de Pontos de Troca de Tráfego (IX.br), o tratamento de incidentes de segurança (CERT.br) e o estudo das tecnologias de redes e operações (Ceptro.br), e aquelas voltadas ao desenvolvimento global da Web (Ceweb.br), pesquisas sobre aspectos da difusão da Internet em nossa sociedade geram subsídios importantes para formulação e monitoramento de políticas públicas. A produção de indicadores sobre a adoção das tecnologias de informação e comunicação tem sido ferramenta fundamental para medição dos impactos da Internet em diferentes camadas da sociedade brasileira.

A agenda envolvendo a IA pressupõe ainda maior relevância no monitoramento da adoção das tecnologias pelos diversos setores, como saúde, educação e cultura, contemplando também a transformação digital das empresas, dos serviços governamentais e o acesso nos domicílios, especialmente por crianças e adolescentes. As pesquisas desenvolvidas periodicamente há 15 anos pelo Centro Regional de Estudos para o Desenvolvimento da Sociedade da Informação (Cetic.br) representam, assim, um esforço permanente no acompanhamento do desdobramento dos efeitos tecnológicos em aspectos econômicos e sociais.

O NIC.br também tem adotado iniciativas específicas visando a um maior aprofundamento sobre IA. Houve, internamente, a criação de um grupo de trabalho envolvendo seus diversos centros de estudo: o NICEIA – NIC Estudos em IA. Além disso, o NIC.br, por meio do Cetic.br, viabilizou uma parceria com a Organização das Nações Unidas para a Educação, a Ciência e a Cultura (Unesco) para realização do importante Fórum Regional de Inteligência Artificial na América Latina e no Caribe em São Paulo. Com apoio e participação da Universidade de São Paulo (USP), do CGI.br, do Ministério da Ciência, Tecnologia, Inovações e Comunicações (MCTIC) e do Ministério das Relações Exteriores (MRE), o fórum foi realizado em dezembro de 2019¹ e constituiu um marco importante na abordagem multissetorial e humanística desse debate. Outro evento, o Workshop sobre IA e Crianças, promovido pelo Fundo das Nações Unidas para a Infância (Unicef) em março de 2020², destacou-se como *locus* de consulta envolvendo diversos setores como governos, empresas, sociedade civil e usuários acerca das oportunidades e riscos trazidos pelos sistemas de IA às nossas crianças.

Partindo de alguns princípios já consensuados³ e da atuação multissetorial baseada em evidências, esperamos contribuir para que o avanço da IA siga no sentido da promoção do bem-estar, da justiça e da equidade, respeitando critérios de segurança, responsabilidade, transparência e privacidade.

Demi Getschko

Núcleo de Informação e Coordenação do Ponto BR – NIC.br

¹ Mais informações no *website* do fórum. Recuperado em 30 março, 2020, de <https://unesco-regional-forum-ai.cetic.br/pt/>

² Mais informações no *website* do Cetic.br. Recuperado em 30 março, 2020, de <https://cetic.br/noticia/nic-br-sedia-evento-do-unicef-sobre-inteligencia-artificial-e-uso-das-tic-por-criancas-e-adolescentes/>

³ Burle, C., & Cortiz, D. (2020). *Mapeamento de princípios de inteligência artificial*. São Paulo: CGI.br.

Apresentação

No contexto atual, em que todos os países enfrentam a pandemia COVID-19 e suas consequências sociais e econômicas, fica cada vez mais evidente o papel das tecnologias de informação e comunicação (TIC) nos diversos aspectos de nosso cotidiano. As tecnologias digitais estão presentes de forma pervasiva em todos os elementos da vida em sociedade, dos costumes e da economia, sendo essencial que seu desenvolvimento conte com a participação de todos os atores potencialmente impactados pelo seu uso.

Esse cenário complexo tem exigido dos países um rápido avanço na adoção das TIC em muitos setores: nas empresas, na educação, no comércio, na saúde, no governo, entre outros. Diante da transformação digital que vivenciamos – em que florescem uma economia movida por dados e aplicações baseadas em Inteligência Artificial (IA) – há uma corrida global para liderar os aspectos cruciais do desenvolvimento de suas tecnologias básicas associadas, numa junção de esforços intelectuais e financeiros que dará ao país desenvolvedor vantagens comparativas frente aos demais. Nas nações emergentes, as tecnologias aplicadas e baseadas em IA terão papel crucial para estimular o desenvolvimento socioeconômico, seja na apropriação de vantagens comparativas no cenário global, seja na melhoria da qualidade e da eficiência dos serviços entregues à população. Isto é, esses conjuntos de tecnologias baseadas em IA deverão aumentar substantivamente a produtividade das economias que as adotarem, bem como as expandir de forma competente.

Para além dos benefícios associados à transformação digital, há ainda muitas incertezas em diversos aspectos de sua implementação. Com a difusão das aplicações baseadas em IA, é fundamental que sejam desenvolvidos estudos mais aprofundados que ajudem na compreensão de seu alcance, de seus impactos econômicos e de suas consequências sociais. É imprescindível conhecer as possíveis mudanças no comportamento humano causadas pela lógica dos algoritmos, o que vai determinar o grau de regulação necessário, dentre diversos outros aspectos.

Para todos esses campos, faz-se necessário aprofundar as iniciativas de pesquisa e desenvolvimento tecnológico. Nessa perspectiva, o Ministério da Ciência, Tecnologia e Inovações (MCTI) lidera a construção de uma Estratégia Brasileira de Inteligência Artificial,

que certamente irá contribuir para a identificação de áreas prioritárias para o desenvolvimento e uso das tecnologias relacionadas, e por meio das quais há maior potencial de obtenção de benefícios para o país. Nesse contexto, compete destacar o esforço conjunto do Comitê Gestor da Internet no Brasil (CGI.br), do MCTI, do Ministério das Comunicações (MCom) e da Fundação de Amparo à Pesquisa do Estado de São Paulo (Fapesp) para apoiar a criação de centros de pesquisas aplicadas em IA – o que sem dúvida trará inúmeros avanços para a geração de conhecimento e, subsequentemente, deverá gerar riquezas e melhoria na qualidade de vida de toda a população brasileira.

Cabe lembrar que o diálogo construtivo entre o governo e a sociedade é pedra fundamental na origem do CGI.br, dado o seu caráter multissetorial e sua permanente busca de consensos entre o setor privado, a academia, o terceiro setor e o poder público, cada um no seu respectivo papel na governança da Internet no Brasil. Isso permitiu, por meio do Núcleo de Informação e Coordenação do Ponto BR (NIC.br), a construção de importantes iniciativas para o desenvolvimento da Internet brasileira. Dentre elas, podemos citar a marca de mais de 4 milhões de nomes de domínio sob o “.br”, a implementação de uma das maiores redes de Pontos de Troca de Tráfego do mundo, o IX.br, a elaboração de cartilhas sobre segurança na Internet e proteção de dados, a medição da qualidade da Internet oferecida nas escolas públicas e para a sociedade em geral, e o estabelecimento de um centro de estudos de tecnologias web.


Destaca-se, dentre as iniciativas, o Centro Regional de Estudos para o Desenvolvimento da Sociedade da Informação (Cetic.br), que, em 2020, completa 15 anos. O centro desempenha um papel relevante na produção de estatísticas sobre o desenvolvimento da sociedade da informação e, desde 2012, é também um centro regional de estudos sob os auspícios da Organização das Nações Unidas para a Educação, a Ciência e a Cultura (Unesco). Por meio das pesquisas TIC do CGI.br, é possível monitorar os avanços e subsidiar políticas públicas que venham a ser desenhadas para que a utilização das TIC tenha efeitos cada vez mais positivos para a sociedade e a economia.

Apoiado pelo governo brasileiro, em dezembro de 2019 foi realizado o Fórum Regional de Inteligência Artificial na América Latina e no Caribe, da Unesco, organizado pelo CGI.br e pelo NIC.br. Na oportunidade, o Brasil deu uma contribuição relevante para o debate do tema na região. As discussões apoiaram autoridades de países em desenvolvimento para que possam aumentar seu nível de prontidão frente à IA, o que facilitará a definição dos papéis dessas nações sobre o tema.

O CGI.br entende que, assim como a Internet, a Inteligência Artificial e as tecnologias 4.0 serão tão mais rapidamente implementadas quanto maior for o envolvimento dos diferentes setores em seu desenvolvimento e que a definição de princípios mínimos para a sua adoção é primordial. As tecnologias digitais, nesse sentido, devem ser um instrumento a serviço das pessoas, privilegiando o atendimento das necessidades do ser humano, e nunca um fim em si mesmo. Por isso, competências tecnológicas, sociotécnicas e institucionais precisam se desenvolver com velocidade e em trilhas paralelas. Compreender tais desafios deve contribuir para maximizar os benefícios e reduzir os riscos desta jornada premente e transformadora.

Marcio Nobre Migon

Comitê Gestor da Internet no Brasil – CGI.br



RESUMO EXECUTIVO

—
PESQUISA
TIC SAÚDE
2019

Resumo Executivo

TIC Saúde 2019

A pesquisa TIC Saúde investiga o acesso e o uso das tecnologias da informação e comunicação (TIC) nos estabelecimentos de saúde brasileiros e seu uso por médicos e enfermeiros. Nesta sétima edição, realizada em um período imediatamente anterior à disseminação da pandemia COVID-19 no Brasil, os resultados possibilitam um mapeamento da saúde digital no país e da preparação do sistema de saúde para o novo momento.

Do ponto de vista da infraestrutura, a disponibilização de computadores e do acesso à Internet nos estabelecimentos de saúde vem aumentando nos últimos anos. Em 2019, verificou-se que os estabelecimentos privados, os das capitais, os com internação e os de serviço de apoio à diagnose e terapia (SADT) lograram a universalização do uso de computador e Internet. Os estabelecimentos que apresentaram uma menor conectividade foram os públicos (92% tinham computador e 85% tinham Internet); os sem internação e os localizados no interior (95% tinham computador e cerca de 90% tinham acesso à Internet). Também foram

verificadas diferenças regionais, conforme apontado na Figura 1.

Entre os estabelecimentos com acesso à Internet, a conexão mais utilizada foi via cabo ou fibra ótica, chegando em 86% dos estabelecimentos de saúde em 2019. Já a conexão via linha telefônica (DSL) diminuiu gradativamente nos últimos anos, mas ainda atendeu 43% dos estabelecimentos. As conexões via rádio e via satélite foram utilizadas por 13% e 8% dos estabelecimentos, respectivamente, sendo mais utilizadas nas regiões Norte e Centro-Oeste.

A velocidade máxima para *download* da conexão principal dos estabelecimentos de saúde vem crescendo nos últimos anos – tendência também verificada em outras pesquisas do Cetic.br/NIC.br. As conexões acima de 100 Mbps passaram de 4%, em 2018, para 11% dos estabelecimentos, em 2019. Destaca-se que as diferenças no acesso às velocidades acima de 10 Mbps ocorreram, principalmente, entre os estabelecimentos públicos (20%) e privados (60%) e os sem internação (38%) e os com internação e mais de 50 leitos (75%). Esses resultados evidenciam a persistência de disparidades no acesso, principalmente entre os estabelecimentos públicos.

Informações dos pacientes em formato eletrônico

O uso de sistemas eletrônicos para registro de informações clínicas dos pacientes é uma importante ferramenta para a integração do cuidado do paciente e para a melhora da qualidade e eficiência do sistema de saúde. Em um cenário de pandemia, o acesso rápido a informações seguras dos pacientes permite o monitoramento dos que se encontram em grupo de risco e a agregação de dados para a tomada de decisões sobre a saúde pública. Os resultados de 2019 apresentaram um avanço, com 82% dos estabelecimentos tendo estes sistemas, enquanto, em 2018, esse número era 73%. As menores proporções de estabelecimentos com sistema eletrônico foram na esfera pública, nos com internação até 50 leitos e nas regiões Norte e Nordeste, conforme Gráfico 1.

GOVERNANÇA DE TI E SEGURANÇA DA INFORMAÇÃO

Em relação à gestão e governança de tecnologia da informação (TI), em 65% dos estabelecimentos públicos o suporte técnico em informática foi realizado por um prestador de serviço contratado pela secretaria de saúde, enquanto 69% dos privados tinham um prestador contratado pelo próprio estabelecimento. Os estabelecimentos com internação e com mais de 50 leitos foram os únicos em que a maior proporção (67%) mantinha uma equipe interna para este serviço.

Quanto à segurança da informação, a ferramenta que apresentou a maior variação positiva em relação à edição anterior foi a biometria para acesso ao sistema eletrônico (de 8% para 16%). Os estabelecimentos com internação (mais de 50 leitos) e os SADT foram os que apresentaram os melhores resultados na adoção de ferramentas de segurança (Gráfico 2). Nesta edição, foram incluídas duas novas ferramentas: *data loss protection/prevention* (DLP), presente em 22% dos estabelecimentos de saúde, e o duplo fator de autenticação, instalado em 7% dos estabelecimentos. Essas ferramentas podem fortalecer a segurança contra vazamentos de informações: a primeira monitora ocorrências e vulnerabilidades do sistema; e a segunda restringe o acesso por pessoas não autorizadas.

DADOS DOS PACIENTES EM FORMATO ELETRÔNICO

Em 2019, verificou-se um aumento na disponibilidade de informações do paciente em formato eletrônico. Entre os principais aumentos em relação à 2018 estão: dados cadastrais dos pacientes (89% contra 79%); principais motivos que levaram o paciente à consulta (64% contra 50%) e admissão, transferência e alta (56% contra 43%).

Quanto às funcionalidades do sistema eletrônico, o destaque fica por conta do aumento de sua disponibilidade nos estabelecimentos públicos

nos últimos anos, principalmente: listar todos os resultados de exames laboratoriais (de 17%, em 2016, para 41%, em 2019), listar todos os pacientes que fazem uso de uma medicação (de 18%, em 2016, para 40%, em 2019) e realizar prescrição médica (de 29% para 51%). Esses aumentos podem indicar uma evolução no nível e na complexidade dos sistemas eletrônicos adotados.

CERCA DE UM QUARTO DOS ESTABELECIMENTOS OFERECERAM AGENDAMENTO DE CONSULTAS E EXAMES E VISUALIZAÇÃO DE RESULTADOS DE EXAMES ON-LINE

PRESENÇA NA INTERNET E TELESSAÚDE

Em um momento de crise sanitária, tanto a comunicação como os serviços de saúde virtuais têm tido um relevante papel para que sejam cumpridas as recomendações de isolamento social e enfrentamento da pandemia. Em 2019, os estabelecimentos privados (50%), os com internação e

mais de 50 leitos (51%) e os SADT (48%) tinham tanto *websites* como perfis em redes sociais. No entanto, mais da metade dos estabelecimentos públicos (57%) e cerca de quatro em cada dez estabelecimentos sem internação (39%) e com internação até 50 leitos (44%) não tinham nenhum *website* nem perfil em rede social.

Serviços *on-line* foram disponibilizados em menor proporção pelos estabelecimentos públicos em relação aos privados. Os SADT foram os que mais ofereceram agendamento de exames (39%) e visualização de resultados de exames (60%) via Internet.

Quanto aos serviços de telessaúde, a pesquisa investigou os que estavam autorizados no período pré-pandemia e, como vem acontecendo ao longo da série histórica, são os estabelecimentos públicos que têm maior disponibilidade desses serviços. Os principais serviços oferecidos foram educação a distância em saúde, serviços de teleconsultoria e atividades de pesquisa a distância.

ADOÇÃO DAS TIC NAS UNIDADES BÁSICAS DE SAÚDE

Nesta edição, destacam-se os resultados para as Unidades Básicas de Saúde (UBS), por serem

FIGURA 1

USO DE COMPUTADOR E INTERNET NOS ÚLTIMOS 12 MESES (2019)

Total de estabelecimentos de saúde (%)



GRÁFICO 1

EXISTÊNCIA DE SISTEMA ELETRÔNICO PARA REGISTRO DAS INFORMAÇÕES DOS PACIENTES (2019)

Total de estabelecimentos de saúde que utilizaram a Internet nos últimos 12 meses (%)





GRÁFICO 2

TIPO DE FERRAMENTA DE SEGURANÇA DA INFORMAÇÃO UTILIZADA (2019)

Total de estabelecimentos de saúde que utilizaram a Internet nos últimos 12 meses (%)



a porta de entrada para o Sistema Único de Saúde (SUS) e por desempenharem um papel fundamental no acompanhamento da saúde da população local e na prevenção de doenças. Os resultados de 2019 apontam que 91% tinham computador e 82% tinham acesso à Internet, resultado que permaneceu estável em relação a 2018. No entanto, houve uma variação positiva em relação a adoção de sistemas eletrônicos para registro de informações dos pacientes, com aumento de 69%, em 2018, para 78%, em 2019.

Estas variações positivas também foram verificadas em relação ao percentual de UBS com dados dos pacientes disponíveis eletronicamente. Em 2019, verificou-se aumento em todos os itens investigados, conforme apontado no Gráfico 4. Esses resultados podem indicar uma tendência de transição das UBS para a saúde digital.

Também foram verificadas variações positivas em relação ao percentual de UBS com funcionalidades eletrônicas disponíveis nos sistemas. Esse aumento se deu, principalmente, em funcionalidades como pedir exames laboratoriais e realizar prescrição médica.

Quanto à presença das UBS na Internet, 21% têm *websites* e 20% possuem uma conta ou perfil em redes sociais. A disponibilização de serviços *on-line* para a população, como agendamento de consultas e exames e visualização de exames, estava presente em cerca de um quarto delas (Gráfico 5).

Já a disponibilização dos serviços de telessaúde foi maior, visto que 39% tinham educação a distância, 25% tinham telediagnóstico e 30% tinham atividades de pesquisa a distância.

ACESSO E USO DAS TIC PELOS PROFISSIONAIS DE SAÚDE

A disponibilidade de computador e Internet para o uso dos profissionais vem se mantendo estável nos últimos anos. Entre os médicos, 88% tinham acesso a computador e 94% acesso à Internet nos estabelecimentos de saúde.

Destaca-se que nos estabelecimentos públicos, 23% dos médicos e 14% dos enfermeiros não tinham computador disponível. Entre os médicos com acesso a computador, 54% realizavam a prescrição médica em formato eletrônico e 31% realizavam tanto manual quanto eletronicamente. Apesar disso, 71% assinavam manualmente as prescrições médicas.

Entre as ferramentas de telessaúde, a educação a distância foi a mais disponível para os profissionais (mais de 40% para ambos). A pesquisa a distância, teleconsultoria e segunda

opinião formativa estavam disponíveis para cerca de um quarto dos profissionais.

Quanto à percepção dos profissionais em relação aos impactos do uso das TIC, 83% dos médicos avaliaram que houve redução dos erros na administração de medicamentos e também melhora da qualidade do tratamento como um todo.


Entre os enfermeiros, 91% acreditam que houve maior eficiência nos atendimentos e 88% que houve melhora no atendimento como um todo.

88% DOS MÉDICOS
E 94% DOS
ENFERMEIROS
AVALIAM QUE O USO
DAS TIC MELHOROU
OS PROCESSOS
DE TRABALHO DAS
EQUIPES

Metodologia da pesquisa e acesso aos dados

Nesta edição foram entrevistados 2.427 gestores de estabelecimentos de saúde, 1.732 médicos e 2.458 enfermeiros vinculados a estes estabelecimentos. A coleta dos dados foi realizada por entrevistas via telefone entre julho de 2019 e fevereiro de 2020. Os resultados da pesquisa TIC Saúde, incluindo as tabelas de proporções, totais e margens de erro, estão disponíveis no *website* (<http://www.cetic.br>) e no portal de visualização de dados do Cetic. br (<http://data.cetic.br/cetic>). O relatório metodológico e o relatório de coleta de dados podem ser consultados tanto na publicação impressa como no *website*.

GRÁFICO 3
SERVIÇOS DE TELESSAÚDE DISPONÍVEIS (2019)
Total de estabelecimentos de saúde que utilizaram a Internet nos últimos 12 meses (%)



40.880

UBS consideradas na pesquisa TIC Saúde 2019

3.581

UBS que não possuem computador

3.637

UBS que não possuem conexão à Internet

7.270

UBS com acesso à Internet e que não possuem sistema eletrônico


GRÁFICO 4
UBS, POR TIPO DE DADO SOBRE O PACIENTE DISPONÍVEL ELETRONICAMENTE (2018 E 2019)

Total de estabelecimentos de saúde que utilizaram a Internet nos últimos 12 meses (%)



GRÁFICO 5
UBS, POR SERVIÇOS OFERECIDOS AO PACIENTE VIA INTERNET (2019)

Total de estabelecimentos de saúde que utilizaram a Internet nos últimos 12 meses (%)





Acesse os dados completos da pesquisa

A publicação completa e os resultados da pesquisa estão disponíveis no *website* do **Cetic.br**, incluindo as tabelas de proporções, totais e margens de erros.



RELATÓRIO METODOLÓGICO

PESQUISA
TIC SAÚDE
2019

Relatório Metodológico TIC Saúde

O Comitê Gestor da Internet no Brasil (CGI.br), por meio do Centro Regional de Estudos para o Desenvolvimento da Sociedade da Informação (Cetic.br), do Núcleo de Informação e Coordenação do Ponto BR (NIC.br), apresenta o “Relatório Metodológico” da Pesquisa sobre o uso das tecnologias de informação e comunicação nos estabelecimentos de saúde brasileiros – TIC Saúde. O estudo é realizado em todo o território nacional, abordando temas relativos à penetração das TIC nos estabelecimentos de saúde e sua apropriação por profissionais de saúde.

Os dados obtidos pela investigação visam contribuir para a formulação de políticas públicas específicas da área de saúde, de forma a gerar insumos para gestores públicos, estabelecimentos de saúde, profissionais de saúde, academia e sociedade civil. A pesquisa conta com o apoio institucional de organismos internacionais – como a Organização para a Cooperação e Desenvolvimento Econômico (OCDE), a Comissão Econômica para a América Latina e o Caribe (Cepal) e a Organização das Nações Unidas para a Educação, a Ciência e a Cultura (Unesco) –, do Ministério da Saúde, por meio do Departamento de Informática do Sistema Único de Saúde (Datasus), da Agência Nacional de Saúde Suplementar (ANS), além de outros representantes do governo, sociedade civil e de especialistas vinculados a importantes universidades.

A pesquisa TIC Saúde é uma iniciativa que incorpora o modelo desenvolvido pela OCDE para as estatísticas no setor. O guia produzido pela organização, chamado *OECD Guide to measuring ICTs in the health sector*:

(...) foi desenvolvido com a intenção de fornecer uma referência padrão para estatísticos, analistas e formuladores de políticas da área de tecnologias de comunicação e informação (TIC) em saúde. O objetivo é facilitar a coleta transnacional de dados, as comparações e a aprendizagem sobre a disponibilidade e o uso das TIC em saúde (Organização para Cooperação e Desenvolvimento Econômico [OCDE], 2015, p. 2).

Objetivos da pesquisa

O objetivo geral da pesquisa TIC Saúde é compreender o estágio de adoção das TIC nos estabelecimentos de saúde brasileiros e sua apropriação pelos profissionais da área. E, nesse contexto, a pesquisa possui os seguintes objetivos específicos:

I. Penetração das TIC nos estabelecimentos de saúde

- Identificar a infraestrutura de TIC disponível nos estabelecimentos de saúde brasileiros;
- Investigar o uso dos sistemas e aplicações baseados em TIC destinados a apoiar serviços assistenciais e a gestão dos estabelecimentos.

II. Apropriação das TIC por profissionais de saúde

- Investigar as habilidades dos profissionais e as atividades realizadas por eles com o uso de TIC;
- Compreender as motivações e barreiras para a adoção das TIC e seu uso por profissionais de saúde.

Conceitos e definições

Estabelecimentos de saúde

Segundo definição adotada pelo Cadastro Nacional de Estabelecimentos de Saúde (CNES), mantido pelo Departamento de Informática do Sistema Único de Saúde (Datasus), estabelecimentos de saúde podem ser definidos de forma abrangente, como sendo qualquer local destinado à realização de ações e/ou serviços de saúde, coletiva ou individual, qualquer que seja o seu porte ou nível de complexidade. Com o objetivo de dar enfoque aos estabelecimentos que trabalhem com uma infraestrutura e instalações físicas destinadas exclusivamente a ações na área de saúde, o estudo também teve como base as definições da Pesquisa de Assistência Médico-Sanitária (AMS) 2009, do Instituto Brasileiro de Geografia e Estatística (IBGE). A Pesquisa de Assistência Médico-Sanitária abrange todos os estabelecimentos de saúde existentes no país que prestam assistência à saúde individual ou coletiva com um mínimo de técnica apropriada, sejam eles públicos ou privados, com ou sem fins lucrativos, segundo os critérios estabelecidos pelo Ministério da Saúde, para atendimento rotineiro, em regime ambulatorial ou de internação. Esse universo abrange postos de saúde, centros de saúde, clínicas ou postos de assistência médica, prontos-socorros, unidades mistas, hospitais (inclusive os de corporações militares), unidades de complementação diagnóstica e/ou terapêutica, clínicas odontológicas, clínicas radiológicas, clínicas de reabilitação e laboratórios de análises clínicas (Instituto Brasileiro de Geografia e Estatística [IBGE], 2010).

Profissionais de saúde

A pesquisa TIC Saúde considera as informações adotadas pelo CNES para a identificação dos profissionais de saúde analisados no estudo. Esses profissionais trabalham em estabelecimentos de saúde, prestando atendimento ao paciente do Sistema Único de Saúde (SUS) ou não. A identificação de médicos e enfermeiros teve como base a Classificação Brasileira de Ocupações (CBO), mantida pelo Ministério do Trabalho e Emprego.

Esfera administrativa

A partir da classificação dada pelo CNES, a pesquisa TIC Saúde considera como sendo públicos os estabelecimentos administrados pelos governos federal, estadual ou municipal. Os demais estabelecimentos (privado com fins lucrativos e privado sem fins lucrativos) são classificados como privados.

Leitos de internação

Instalações físicas específicas destinadas à acomodação de pacientes para permanência por um período mínimo de 24 horas. Os hospitais-dia não são considerados unidades com internação.

Tipo de estabelecimento

Essa classificação é dada pela combinação de características dos estabelecimentos relativas ao tipo de atendimento e ao número de leitos de internação. A referência dessa classificação é a que foi adotada pela Pesquisa de Assistência Médico-Sanitária do IBGE. Assim, foram definidos quatro grupos mutuamente exclusivos de estabelecimentos:

- **Sem internação:** Estabelecimentos sem internação (que não possuem leitos) e realizam outros tipos de atendimento (urgência, ambulatorial, etc.);
- **Com internação (até 50 leitos):** Estabelecimentos que realizam internação e possuem ao menos um leito e até, no máximo, 50 leitos;
- **Com internação (mais de 50 leitos):** Estabelecimentos que realizam internação e possuem 51 ou mais leitos;
- **Serviço de apoio à diagnose e terapia (SADT):** Estabelecimentos sem internação (que não possuem leitos) e destinados exclusivamente a serviços de apoio à diagnose e terapia, definidos como unidades onde são realizadas atividades que auxiliam a determinação de diagnóstico e/ou complementam o tratamento e a reabilitação do paciente, tais como laboratórios.

Tipo de unidade

A partir da classificação do tipo de estabelecimento dada pelo CNES, a pesquisa TIC Saúde considera a seguinte classificação:

- Posto de saúde;
- Centro de saúde/unidade básica;
- Policlínica;
- Hospital geral;
- Clínica/centro de especialidade;
- Unidade de apoio à diagnose e terapia (SADT isolado);
- Centro de atenção psicossocial;
- Pronto atendimento;
- Demais tipos de unidade agregados.

Unidade Básica de Saúde (UBS)¹

Corresponde às UBS ativas no CNES dos seguintes tipos de estabelecimentos:

- Posto de saúde;
- Centro de saúde/unidade básica;
- Unidade mista;
- Centro de apoio à saúde da família.

POPULAÇÃO-ALVO

A população-alvo do estudo é composta por estabelecimentos de saúde brasileiros. Para efeitos da investigação e do levantamento da população de referência, são considerados os estabelecimentos cadastrados no CNES. Assim, a pesquisa tem como escopo os estabelecimentos de saúde públicos e privados cadastrados no CNES, que possuam Cadastro Nacional da Pessoa Jurídica (CNPJ) próprio ou de uma entidade mantenedora, além de instalações físicas destinadas exclusivamente a ações na área de saúde e que possuam ao menos um médico ou um enfermeiro. Dessa forma, não serão considerados no estudo os seguintes estabelecimentos:

- Estabelecimentos cadastrados como pessoas físicas;
- Consultórios isolados, definidos como salas isoladas destinadas à prestação de assistência médica ou odontológica ou de outros profissionais de saúde de nível superior;
- Estabelecimentos criados em caráter provisório e de campanha;
- Unidades móveis (terrestres, aéreas ou fluviais);
- Estabelecimentos que não possuam ao menos um médico ou um enfermeiro vinculado, com exceção dos estabelecimentos classificados como SADT;
- Estabelecimentos destinados à gestão do sistema, como as secretarias de saúde, centrais de regulação e outros órgãos com essas características que se encontram cadastrados no CNES.

Cada estabelecimento é tratado como um conglomerado composto de profissionais com cargos de administração – gestores responsáveis por prestar informações sobre os estabelecimentos – e profissionais de atendimento assistencial – médicos(as) e enfermeiros(as) – que compõem a população-alvo da pesquisa.

UNIDADE DE ANÁLISE

Para atender aos objetivos propostos pela pesquisa, consideram-se como unidades de análise os estabelecimentos de saúde, os médicos e os enfermeiros (profissionais de saúde).

¹ Na população alvo da pesquisa não são consideradas Unidades Móveis, que assim como nos outros estratos, foram excluídas das UBS.

DOMÍNIOS DE INTERESSE PARA ANÁLISE E DIVULGAÇÃO

Para a unidade de análise estabelecimentos de saúde, os resultados serão divulgados para os domínios definidos com base nas variáveis do cadastro e níveis descritos a seguir:

- **Esfera administrativa:** Corresponde à classificação das instituições como públicas ou privadas;
- **Tipo de estabelecimento:** Esta classificação está associada a quatro tipos diferentes de estabelecimentos, levando em conta o tipo de atendimento e o seu porte relativo ao número de leitos – sem internação, com internação (até 50 leitos), com internação (mais de 50 leitos) e SADT;
- **Região:** Corresponde à divisão regional do Brasil em macrorregiões (Norte, Centro-Oeste, Nordeste, Sudeste e Sul), segundo critérios do IBGE;
- **Localização:** Refere-se à informação de que o estabelecimento está localizado na capital ou interior de cada unidade federativa;
- **Identificação de Unidade Básica de Saúde:** Refere-se à classificação em UBS ou Não UBS.

Em relação às unidades de análise profissionais de saúde (médicos e enfermeiros), acrescentam-se aos domínios acima as seguintes características obtidas com base na informação fornecida pelos respondentes:

- **Faixa Etária:** Refere-se à idade do profissional determinada em três faixas, dependendo do público:
 - Para enfermeiros: até 30 anos; de 31 a 40 anos; e de 41 anos ou mais;
 - Para médicos: até 35 anos; de 36 a 50 anos; e de 51 anos ou mais.

Instrumento de coleta

INFORMAÇÕES SOBRE OS INSTRUMENTOS DE COLETA

Para coleta das informações de interesse na pesquisa são construídos dois questionários estruturados, com perguntas fechadas e abertas (quando for o caso): um aplicado para os profissionais administrativos dos estabelecimentos (preferencialmente gestores de tecnologia da informação – TI) e o outro para os profissionais de saúde (médicos e enfermeiros). Mais informações a respeito dos questionários, ver item “Instrumento de coleta” no “Relatório de Coleta de Dados” da Pesquisa TIC Saúde.

Plano amostral

O desenho do plano amostral da TIC Saúde é a amostragem estratificada de estabelecimentos de saúde e a seleção com probabilidade proporcional ao tamanho (PPT). A medida de tamanho é a raiz quadrada do total de pessoas ocupadas cadastradas no CNES.²

CADASTRO E FONTES DE INFORMAÇÃO

O cadastro utilizado para seleção dos estabelecimentos de saúde é o Cadastro Nacional dos Estabelecimentos de Saúde (CNES), mantido pelo Departamento de Informática do Sistema Único de Saúde (Datasus), do Ministério da Saúde. Instituído pela Portaria MS/SAS n. 376, de 3 de outubro de 2000, o CNES reúne os registros de todos os estabelecimentos de saúde, hospitalares e ambulatoriais, componentes das redes pública e privada existentes no país. O cadastro deve manter atualizados os bancos de dados nas bases locais e federal, visando subsidiar os gestores na implantação e na implementação das políticas de saúde.

Os registros são utilizados para subsidiar áreas de planejamento, regulação, avaliação, controle, auditoria, ensino e de pesquisa (Ministério da Saúde, 2006).

CRITÉRIOS PARA DESENHO DA AMOSTRA

As informações sobre tipo de estabelecimento, região, localização dos estabelecimentos e esfera administrativa, variáveis de particular interesse para a divulgação dos resultados, são empregadas na criação dos estratos. Os estabelecimentos sem internação ainda são subdivididos de acordo com a esfera administrativa, UBS e tipo de unidade. A estratificação é empregada na alocação dos estabelecimentos e ajuda a controlar o erro esperado marginalmente para cada variável de interesse.

DIMENSIONAMENTO DA AMOSTRA

A amostra está dimensionada considerando a otimização de recursos e qualidade exigida para apresentação de resultados. As próximas seções dizem respeito à amostra desenhada para a execução da coleta de dados.

ALOCÇÃO DA AMOSTRA

Como um dos objetivos da pesquisa é divulgar os resultados separadamente para os domínios definidos para as variáveis tipo de estabelecimento, região, localização e esfera administrativa, a alocação da amostra de estabelecimentos é definida conforme as classificações dos estabelecimentos nessas mesmas variáveis.

² Foi utilizada a raiz quadrada do total de pessoas ocupadas cadastradas no CNES com vistas a diminuir a variabilidade observada nessa variável, tornando a distribuição menos assimétrica e mais próxima da normal.

A pesquisa conta com 156 estratos para efeito de seleção, originados do cruzamento das variáveis: tipo de estabelecimento (4), região (5), localização do estabelecimento (2), esfera administrativa (2) e para os estabelecimentos sem internação públicos também se considera a variável UBS (2), enquanto para os estabelecimentos sem internação privados se considera a variável tipo de unidade (9). Os estratos possibilitam que todas as variáveis utilizadas estejam representadas na amostra, além de permitir análises para os domínios definidos por essas variáveis individualmente. Contudo, não é possível tirar conclusões para categorias resultantes do cruzamento entre as variáveis.

A alocação da amostra é apresentada no “Relatório de Coleta de Dados” da pesquisa. Para fins de divulgação, não será considerada a divisão por tipo de unidade dos estabelecimentos entre os estabelecimentos sem internação.

A amostra de médicos e enfermeiros é realizada dentro de cada um dos estabelecimentos selecionados para a pesquisa. Não são previstas entrevistas com profissionais de saúde (médicos e enfermeiros) nos estabelecimentos do tipo SADT. A alocação depende do tamanho do estabelecimento e a forma de seleção é descrita a seguir.

SELEÇÃO DA AMOSTRA

Estabelecimentos de saúde

Os estabelecimentos da amostra são selecionados por amostragem proporcional ao tamanho, levando em conta a raiz quadrada da quantidade de pessoas ocupadas de cada organização de acordo com o CNES. Isso significa que estabelecimentos com maior número de pessoas ocupadas têm maior chance de serem selecionados. Em geral, isso é feito com a premissa de que a medida de tamanho utilizada está relacionada com as variáveis de interesse da pesquisa.

Profissionais de saúde

De modo a obter acesso a uma relação atualizada dos profissionais de saúde, é solicitada ao setor administrativo dos estabelecimentos nos quais foram realizadas entrevistas com os gestores uma lista para cada tipo de profissional (médicos e enfermeiros). O processo de listagem ocorre de forma diferenciada para médicos e enfermeiros e depende da quantidade desses profissionais em cada estabelecimento.

Critérios de seleção de médicos

- Se até 20 médicos trabalham no estabelecimento de saúde, todos são listados;
- Se entre 20 e 200 médicos trabalham no estabelecimento de saúde, um departamento é selecionado aleatoriamente para 20 médicos serem listados;
- Se mais de 200 médicos trabalham no estabelecimento de saúde, dois departamentos são selecionados aleatoriamente para 40 médicos serem listados.

Para cada departamento de atendimento selecionado (estabelecimentos de saúde com 20 a 200 médicos e estabelecimentos de saúde com mais de 200 médicos) a listagem é feita da seguinte maneira:

- Se o departamento conta com 20 médicos ou menos, todos são listados;
- Se o departamento conta com mais de 20 médicos, é selecionado aleatoriamente um turno de atendimento para listar os médicos, e:

- Se até 20 médicos trabalham no turno, são selecionados, aleatoriamente, turnos de trabalho sucessivamente até chegar à quantidade de 20 médicos ou mais;
- Se mais de 20 médicos trabalham no turno, todos são listados (por *e-mail*).

Assim, nos estabelecimentos em que a divisão por departamento e turnos ainda resultar em listagem superior a 20 médicos, solicita-se o envio da listagem por *e-mail*. A partir das listagens enviadas, é feita uma seleção aleatória de médicos para responder a pesquisa.

Crítérios de seleção de enfermeiros

- Se até 10 enfermeiros trabalham no estabelecimento de saúde, todos são listados;
- Se entre 10 e 50 enfermeiros trabalham no estabelecimento de saúde, um departamento é selecionado aleatoriamente para 10 enfermeiros serem listados;
- Se mais de 50 enfermeiros trabalham no estabelecimento de saúde, dois departamentos são selecionados aleatoriamente para 20 enfermeiros serem listados.

Para cada departamento de atendimento selecionado (estabelecimentos de saúde com 10 a 50 enfermeiros e estabelecimentos de saúde com mais de 50 enfermeiros), a listagem é feita da seguinte maneira:

- Se o departamento conta com 10 enfermeiros ou menos, todos são listados;
- Se o departamento conta com mais de 10 enfermeiros, é selecionado um turno de atendimento para listar os enfermeiros, e:
 - Se até 10 enfermeiros trabalham no turno, são selecionados aleatoriamente turnos de trabalho sucessivamente até alcançar a quantidade de 10 enfermeiros ou mais;
 - Se mais de 10 enfermeiros trabalham no turno, todos são listados (se esse número exceder 20 enfermeiros, as listagens são recebidas por *e-mail*).

Nos estabelecimentos em que a divisão por departamento e turnos ainda resultar em listagem superior a 10 enfermeiros, solicita-se o envio da listagem por *e-mail*. A partir das listagens enviadas, é feita uma seleção aleatória simples de enfermeiros para responder a pesquisa.

Processamento dos dados

PROCEDIMENTOS DE PONDERAÇÃO

O peso amostral básico é calculado separadamente para cada estrato e cada estabelecimento, considerando a seleção com PPT que foi feita.

Como o tamanho dos estabelecimentos pode variar muito, em certos estratos são encontrados alguns com medida tão grande que entraram na amostra com certeza, isto é, com probabilidade igual a um. Esses estabelecimentos são denominados autorrepresentativos. Sendo assim, o peso básico de cada estabelecimento em cada estrato da amostra é dado pela Fórmula 1.

FÓRMULA 1

$$w_{ih} = \begin{cases} \frac{M_h}{n_h \times m_{ih}}, & \text{se o número de} \\ & \text{pessoas ocupadas} \\ & \text{é inferior ao "passo"} \\ 1, & \text{caso contrário} \end{cases}$$

w_{ih} é o peso básico, inverso da probabilidade de seleção, do estabelecimento i no estrato h

M_h é a raiz quadrada do total de pessoas ocupadas no estrato (exceto estabelecimentos autorrepresentativos) h

n_h é o total da amostra de estabelecimentos, excluindo os autorrepresentativos, no estrato h

m_{ih} é a raiz quadrada do total de pessoas ocupadas no estabelecimento i no estrato h

w_{ih} é o peso básico associado a cada um dos estabelecimentos selecionados. Desses, alguns não respondem a pesquisa. Assim, é realizada uma correção de não resposta associada aos informantes. A correção de não resposta é dada pela Fórmula 2.

FÓRMULA 2

$$w_{ih}^* = \begin{cases} w_{ih} \times \frac{S_h^s}{S_h^r}, & \text{se o estabelecimento} \\ & \text{não era autorrepresentativo} \\ \frac{n_{ph}}{n^e_{ph}}, & \text{caso contrário} \end{cases}$$

w_{ih}^* é o peso com correção de não resposta do estabelecimento i no estrato h

w_{ih} é o peso básico do estabelecimento i no estrato h

S_h^s é a soma total de pesos dos estabelecimentos selecionados no estrato h

S_h^r é a soma total de pesos dos estabelecimentos respondentes no estrato h

n_{ph} é o total de estabelecimentos da amostra autorrepresentativos no estrato h

n^e_{ph} é o total de estabelecimentos autorrepresentativos respondentes no estrato h

Ao final, os pesos corrigidos para não resposta são pós-estratificados para as variáveis de estratificação, para as quais se divulgam resultados (região, localização, tipo de estabelecimento e esfera administrativa). Dessa forma, considerando as variáveis utilizadas para seleção, os totais da amostra somaram os totais do cadastro. A pós-estratificação se dá pela multiplicação do peso corrigido para não resposta w_{ih}^* em cada estrato por um fator que corrige o total do estrato (soma dos pesos com correção de não resposta) para o total da população.

Ponderação dos médicos

O universo de médicos considerado pela pesquisa é definido como:

- Médicos não residentes vinculados aos estabelecimentos de saúde do tipo sem internação;
- Médicos não residentes vinculados aos estabelecimentos com internação de qualquer porte.

São excluídos do universo os estabelecimentos de serviço de apoio à diagnose e terapia.

O primeiro fator da construção de pesos dos médicos é o peso final dos estabelecimentos informantes da pesquisa. Entre os estabelecimentos de saúde informantes (com correção de não resposta e pós-estratificação), alguns não tiveram resposta de médicos. A taxa de não resposta desse público-alvo é maior que a observada para estabelecimentos. Desse modo, a correção de não resposta para os estabelecimentos onde há alguma entrevista com médicos é realizada por ajuste de um modelo logístico para previsão da probabilidade de resposta de médicos de cada estabelecimento. A partir de variáveis conhecidas do universo de estabelecimentos, estima-se a probabilidade de haver entrevistas com médicos.

O modelo parte das variáveis tipo de estabelecimento, região, localização dos estabelecimentos e esfera administrativa, tamanho do estabelecimento (em faixas) e identificação do cargo do respondente. Busca-se que o modelo classifique respondente e não respondentes corretamente em pelo menos 60% dos estabelecimentos. O resultado do modelo são as probabilidades de resposta estimadas para cada um dos estabelecimentos informantes da pesquisa; corrige-se, então, a não resposta pela Fórmula 3.

FÓRMULA 3

$$m_{ih} = w_{ih}^* \times \frac{1}{p_r}$$

m_{ih} é o peso com correção de não resposta para entrevista com médicos no estabelecimento i no estrato h

w_{ih}^* é o peso do estabelecimento i no estrato h

p_r é a probabilidade de o estabelecimento ser respondente segundo modelo logístico para ajuste da não resposta

O segundo fator de construção do peso dos médicos informantes refere-se à probabilidade de o médico ser selecionado para pesquisa no estabelecimento. A utilização do procedimento de seleção de dias/turnos não permite a seleção de médicos nos fins de semana (não há coleta nesses dias). Por esse motivo, calcula-se uma probabilidade de seleção *ad hoc*, na qual se considera que os médicos informantes dia/turno são selecionados aleatoriamente no total de médicos. Sendo assim, o peso dos médicos no estabelecimento é dado pela Fórmula 4.

FÓRMULA 4

$$m_{ih}^e = \frac{N_{ih}^m}{n_{ihr}^m}$$

m_{ih}^e é o peso com correção de não resposta para entrevista com médicos no estabelecimento i no estrato h

N_{ih}^m é o total de médicos informado pelo estabelecimento i no estrato h

n_{ihr}^m é o total de médicos respondentes no estabelecimento i no estrato h

O peso final dos médicos (m_{ih}^*) é dado pela multiplicação dos dois fatores: $m_{ih}^* = m_{ih} \times m_{ih}^e$

Ponderação dos enfermeiros

O universo de enfermeiros considerado pela pesquisa é definido pelos profissionais que trabalham nos estabelecimentos de saúde do tipo sem internação e com internação de qualquer porte. São excluídos do universo os estabelecimentos de serviço de apoio à diagnose e terapia.

O primeiro fator da construção de pesos dos enfermeiros é o peso final dos estabelecimentos informantes da pesquisa. Entre os estabelecimentos de saúde informantes (com correção de não resposta e pós-estratificação) alguns não tiveram resposta de enfermeiros. A taxa de não resposta desse público-alvo é maior que a observada para estabelecimentos. Desse modo a correção de não resposta para os estabelecimentos onde há alguma entrevista com enfermeiros é realizada por ajuste de um modelo logístico para previsão da probabilidade de resposta de enfermeiros de cada estabelecimento. A partir de variáveis conhecidas do universo de estabelecimentos, estima-se a probabilidade de haver entrevistas com enfermeiros.

O modelo parte das variáveis tipo de estabelecimento, região, localização dos estabelecimentos e esfera administrativa, tamanho do estabelecimento (em faixas) e identificação do cargo do respondente. Busca-se que o modelo classifique respondentes e não respondentes corretamente em pelo menos 60% dos estabelecimentos. O resultado do modelo são as probabilidades de resposta estimadas para cada um dos estabelecimentos informantes da pesquisa; corrige-se, então, a não resposta pela Fórmula 5.

FÓRMULA 5

$$e_{ih} = w_{ih}^+ \times \frac{1}{p_r}$$

e_{ih} é o peso com correção de não resposta para entrevista com enfermeiros no estabelecimento i no estrato h

w_{ih}^+ é o peso do estabelecimento i no estrato h

p_r é a probabilidade de o estabelecimento ser respondente segundo modelo logístico para ajuste da não resposta

O segundo fator de construção do peso dos enfermeiros informantes na pesquisa refere-se à probabilidade de o enfermeiro ser selecionado para pesquisa no estabelecimento. Como o procedimento adotado é o mesmo para médicos e enfermeiros, adota-se o mesmo plano de ponderação. O peso dos enfermeiros no estabelecimento é dado pela Fórmula 6.

FÓRMULA 6

$$e_{ih}^e = \frac{N_{ih}^e}{n_{ihr}^e}$$

e_{ih}^e é o peso com correção de não resposta para entrevista com enfermeiros no estabelecimento i no estrato h

N_{ih}^e é o total de enfermeiros informado pelo estabelecimento i no estrato h

n_{ihr}^e é o total de enfermeiros respondentes no estabelecimento i no estrato h

O peso final dos enfermeiros (e_{ih}^*) é dado pela multiplicação dos dois fatores: $e_{ih}^* = e_{ih} \times e_{ih}^e$

CALIBRAÇÃO DOS PESOS DE MÉDICOS E ENFERMEIROS

Os pesos amostrais de médicos e enfermeiros são calibrados para refletir os totais populacionais conhecidos, obtidos no cadastro do CNES. Esse procedimento, juntamente com as correções de não resposta, tem por objetivo corrigir a variabilidade associada à não resposta da população de profissionais de saúde.

As variáveis consideradas para calibração e utilizadas para estratificação da amostra são: tipo de estabelecimento, região, localização e esfera administrativa.

A calibração dos pesos foi feita por meio de um programa no *software* SPSS.

ERROS AMOSTRAIS

As medidas ou estimativas da precisão amostral dos indicadores da TIC Saúde levaram em consideração em seus cálculos o plano amostral por estratos empregado na pesquisa.

O método do conglomerado primário (do inglês, *ultimate cluster*) foi utilizado para estimação de variâncias para estimadores de totais em planos amostrais de múltiplos estágios. Proposto por Hansen, Hurwitz e Madow (1953), o método considera apenas a variação entre informações disponíveis no nível das unidades primárias de amostragem (UPA) e admite que estas teriam sido selecionadas com reposição.

Com base no método, pode-se considerar a estratificação e a seleção com probabilidades desiguais, tanto das unidades primárias como das demais unidades de amostragem. As premissas para permitir a aplicação desse método é que estejam disponíveis estimadores não viciados dos totais da variável de interesse para cada um dos conglomerados primários selecionados, e que pelo menos dois destes sejam selecionados em cada estrato (se a amostra for estratificada no primeiro estágio).

Esse método fornece a base para vários dos pacotes estatísticos especializados em cálculo de variâncias considerando o plano amostral.

A partir das variâncias estimadas opta-se pela divulgação dos erros amostrais expressos pela margem de erro. Para a divulgação, essas margens foram calculadas para um nível de confiança de 95%. Assim, se a pesquisa for repetida, em 19 de cada 20 vezes o intervalo conterá o verdadeiro valor populacional.

Normalmente, também são apresentadas outras medidas derivadas dessa estimativa de variabilidade, tais como erro padrão, coeficiente de variação ou intervalo de confiança.

O cálculo da margem de erro considera o produto do erro padrão (raiz quadrada da variância) pelo valor 1,96 (valor da distribuição amostral que corresponde ao nível de significância escolhido de 95%). Esses cálculos são feitos para cada variável de cada uma das tabelas. Portanto, todas as tabelas de indicadores têm margens de erro relacionadas a cada estimativa apresentada em cada célula da tabela.

Disseminação dos dados

Os resultados desta pesquisa são divulgados de acordo com os domínios de análise: esfera administrativa, região, tipo de estabelecimento, identificação de UBS e localização para informações sobre o estabelecimento de saúde, além da variável faixa etária para informações sobre os profissionais de saúde.

Arredondamentos fazem com que, em alguns resultados, a soma das categorias parciais difira de 100% em questões de resposta única. O somatório de frequências em questões de respostas múltiplas usualmente é diferente de 100%. Vale ressaltar que, nas tabelas de resultados, o hífen (–) é utilizado para representar a não resposta ao item. Por outro lado, como os resultados são apresentados sem casa decimal, as células com valor zero significam que houve resposta ao item, mas ele é explicitamente maior do que zero e menor do que um.

Os resultados desta pesquisa são publicados em formato *on-line* e disponibilizados no *website* (<http://www.cetic.br>) e no portal de visualização de dados do Cetic.br (<http://data.cetic.br/cetic>). As tabelas de proporções, totais e margens de erros calculadas para cada indicador estão disponíveis para *download* em português, inglês e espanhol. Mais informações sobre a documentação, os metadados e as bases de microdados da pesquisa estão disponíveis na página de microdados do Cetic.br (<https://cetic.br/microdados/>).

Referências

Hansen, M. H., Hurwitz, W. N., & Madow, W. G. (1953). *Sample survey methods and theory*. Nova Iorque: Wiley.

Instituto Brasileiro de Geografia e Estatística – IBGE. (2010). *Pesquisa Assistência Médico-Sanitária 2009*. Rio de Janeiro: IBGE. Recuperado em 21 setembro, 2020, de <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=283176>

Ministério da Saúde. (2000). *Cadastro Nacional dos Estabelecimentos de Saúde*. Instituído pela Portaria MS/SAS 376, de 3 de outubro de 2000. Recuperado em 01 março, 2019, de <http://cnes.datasus.gov.br/>

Ministério da Saúde. (2006). *Manual do Cadastro Nacional dos Estabelecimentos de Saúde (CNES) – Versão 2*. Recuperado em 21 setembro, 2020, de <http://cnes.datasus.gov.br/pages/downloads/documentacao.jsp>

Organização para Cooperação e Desenvolvimento Econômico – OCDE. (2015). *Draft OECD guide to measuring ICTs in the health sector*. Recuperado em 21 setembro, 2020, de <https://www.oecd.org/health/health-systems/Draft-oecd-guide-to-measuring-icts-in-the-health-sector.pdf>

RELATÓRIO DE COLETA DE DADOS

PESQUISA
TIC SAÚDE

2019

Relatório de Coleta de Dados TIC Saúde 2019

O Comitê Gestor da Internet no Brasil (CGI.br), por meio do Centro Regional de Estudos para o Desenvolvimento da Sociedade da Informação (Cetic.br), do Núcleo de Informação e Coordenação do Ponto BR (NIC.br), apresenta o “Relatório de Coleta de Dados” da pesquisa TIC Saúde 2019. O objetivo do relatório é informar características específicas da edição de 2019 do estudo, contemplando eventuais alterações realizadas nos instrumentos de coleta, a alocação da amostra implementada neste ano e as taxas de resposta verificadas.

A apresentação da metodologia completa da pesquisa, incluindo os objetivos, os principais conceitos e definições e as características do plano amostral empregado, está descrita no “Relatório Metodológico”, que também está publicado nesta edição.

Instrumento de coleta

INFORMAÇÕES SOBRE OS INSTRUMENTOS DE COLETA

A coleta de dados foi realizada por meio de dois questionários estruturados, um aplicado aos profissionais administrativos dos estabelecimentos (preferencialmente gestores de tecnologia da informação – TI) e o outro aos profissionais de saúde (médicos e enfermeiros). Assim, as informações sobre os estabelecimentos de saúde foram obtidas por meio dos profissionais de nível gerencial, enquanto médicos e enfermeiros responderam as questões sobre suas próprias rotinas de trabalho, conforme definições descritas no tópico “Conceitos e Definições”.

O questionário sobre os estabelecimentos contém informações a respeito da infraestrutura de TIC, gestão de tecnologia da informação (TI), registro eletrônico em saúde, troca de informações, serviços *on-line* oferecidos ao paciente e telessaúde. O questionário destinado aos profissionais investiga o perfil desse público, além do acesso, uso e apropriação das TIC.

ALTERAÇÕES NOS INSTRUMENTOS DE COLETA

Tendo como base os resultados das entrevistas realizadas durante os pré-testes, foram feitas alterações nos questionários da pesquisa, sobretudo com o objetivo de adequá-los aos padrões em discussão nos fóruns internacionais para a coleta de dados sobre o uso de tecnologias de informação e comunicação no setor de saúde.

Outras modificações foram realizadas como forma de testar novos itens relevantes para a compreensão do cenário do acesso e uso das TIC no setor, bem como para aperfeiçoar a coleta de dados.

Dentre as principais modificações no questionário sobre os estabelecimentos, estão as seguintes:

Módulo B – Infraestrutura de TIC no estabelecimento:

- Inclusão de novo indicador que investiga o treinamento de profissionais do estabelecimento em segurança da informação.
- Inclusão de dois novos itens sobre o uso de ferramentas de segurança da informação nos estabelecimentos de saúde: duplo fator de autenticação e proteção contra vazamento de informação (*data loss prevention/protection* - DLP).

ENTREVISTAS COGNITIVAS

Entrevistas cognitivas foram realizadas para subsidiar a alteração dos questionários da pesquisa TIC Saúde 2019. A partir dos resultados das entrevistas cognitivas não houve modificação no contexto principal das questões da pesquisa feitas para os gestores dos estabelecimentos de saúde, mas sim alteração para maior clareza de enunciados e itens de perguntas já existentes, como a introdução de exemplos e especificações nos enunciados.

Alterações mais significativas foram feitas no instrumento de coleta dos profissionais de saúde (médicos e enfermeiros). Essas alterações referem-se às perguntas sobre telessaúde e sobre a realização de cursos de informática em saúde. Durante a realização das entrevistas, foram constatadas dificuldades dos respondentes com a formulação que envolviam a apresentação dos conceitos destes temas. Em função disso, esses indicadores passaram por uma reformulação mais profunda e, em ambos os casos, os itens dos enunciados das perguntas foram alterados, de forma a especificar melhor os conceitos.

PRÉ-TESTES

Foram realizadas nove entrevistas com gestores gerais ou de TI de estabelecimentos de saúde, entre os dias 22 e 26 de julho de 2019, e 12 entrevistas com profissionais (seis com médicos e seis com enfermeiros), entre os dias 27 de agosto a 02 de setembro de 2019, em diferentes tipos de estabelecimentos de saúde. Tal distribuição teve como objetivo testar adequação e validade das perguntas e dos indicadores construídos, bem como o tempo de duração dos questionários.

TREINAMENTO DE CAMPO

As entrevistas foram realizadas por uma equipe de profissionais treinados e supervisionados. Esses entrevistadores passaram por treinamento básico de pesquisa; treinamento organizacional; treinamento contínuo de aprimoramento; e treinamento de reciclagem. Além disso, houve um treinamento específico para a pesquisa TIC Saúde 2019, que incluiu a abordagem ao público respondente, o instrumento de coleta, os procedimentos e as ocorrências de campo.

A equipe do projeto também teve acesso ao manual de instruções da pesquisa, que continha a descrição de todos os procedimentos necessários para a realização da coleta de dados e o detalhamento dos objetivos e metodologia da pesquisa, para garantir a padronização e a qualidade do trabalho.

Ao todo, 42 entrevistadores, dois supervisores e dois auxiliares de campo trabalharam na coleta de dados da etapa de gestores de estabelecimentos de saúde. Já na coleta de dados da etapa de profissionais de saúde, trabalharam 52 entrevistadores, dois supervisores e dois auxiliares de campo.

Alocação da amostra

A alocação da amostra de estabelecimentos de saúde é apresentada na Tabela 1.

TABELA 1

ALOCÇÃO DA AMOSTRA DE ESTABELECIMENTOS SEGUNDO REGIÃO, LOCALIZAÇÃO, ESFERA ADMINISTRATIVA E TIPO DE ESTABELECIMENTO

		Amostra
Região	Norte	653
	Nordeste	879
	Sudeste	880
	Sul	727
	Centro-Oeste	688
Localização	Capital	1 290
	Interior	2 537
Esfera administrativa	Público	1 834
	Privado	1 993
Tipo de estabelecimento	Sem internação	1 281
	Com internação (até 50 leitos)	941
	Com internação (mais de 50 leitos)	998
	Serviço de apoio à diagnose e terapia	607

Coleta de dados em campo

MÉTODO DE COLETA

Buscou-se entrevistar o principal gestor do estabelecimento ou gestor que conhecesse a organização como um todo, inclusive no que diz respeito a seus aspectos administrativos e à infraestrutura de TIC presente na organização. Na edição de 2019 da pesquisa TIC Saúde foram buscados preferencialmente os gestores de tecnologia da informação, que responderam as perguntas referentes aos estabelecimentos de saúde. Os profissionais de saúde, médicos não residentes e enfermeiros foram selecionados tal como disposto em “Seleção da amostra” no “Relatório Metodológico”.

Os estabelecimentos foram contatados por meio da técnica de Entrevista Telefônica Assistida por Computador (em inglês, *computer assisted telephone interviewing* – CATI), tanto para gestores quanto para os profissionais de saúde. As entrevistas para aplicação dos questionários tiveram duração aproximada de 36 minutos para gestores e de 20 minutos para médicos e enfermeiros.

DATA DE COLETA

A coleta de dados da TIC Saúde 2019 nos estabelecimentos de saúde amostrados ocorreu entre agosto de 2019 e novembro de 2019 para os gestores e entre setembro de 2019 e fevereiro de 2020 para os profissionais de saúde. As entrevistas com gestores foram feitas entre 8h e 19h do horário de Brasília (UTC-3). Para as entrevistas com médicos e enfermeiros, o horário de realização das entrevistas se deu entre 8h e 19h, de acordo com agendamentos prévios.

PROCEDIMENTOS E CONTROLES DE CAMPO

Foi definido um sistema automatizado com o qual foi possível medir e controlar o esforço para a obtenção das entrevistas. Ele consistiu no tratamento de situações que foram identificadas durante a coleta das informações.

Antes do início do campo, foi realizado um procedimento de limpeza e verificação dos números de telefone que seriam utilizados para contatar os estabelecimentos. Tentou-se contato telefônico com todos os estabelecimentos selecionados na amostra e, sempre que havia algum telefone incorreto ou desatualizado, buscou-se um novo número de contato com o estabelecimento.

Após essa etapa de limpeza do cadastro, os procedimentos realizados foram:

- Contatar o estabelecimento e identificar o respondente. Buscou-se, sempre que possível, entrevistar o gestor responsável pela área de TI do estabelecimento ou, quando não havia esse profissional, o principal gestor responsável pelo estabelecimento. Na impossibilidade de entrevistar o principal responsável, foi identificado um gestor capaz de responder sobre os aspectos gerais do estabelecimento, tais como: informações administrativas, infraestrutura de TIC, recursos humanos, etc. Não foi considerado o profissional que não ocupa cargo de gestão, coordenação e supervisão;

- Agendar e realizar entrevista com o profissional na posição de gestão. Foi informado que a pesquisa possuía duas etapas: uma com os gestores e outra com os profissionais de saúde. Sendo assim, o gestor entrevistado era informado que médicos e enfermeiros também participariam do estudo.

Após a realização da entrevista com o gestor, se o estabelecimento possuía médicos e/ou enfermeiros e era do tipo sem internação, com internação até 50 leitos ou com internação acima de 50 leitos, era aplicado o bloco de obtenção de listagem de profissionais. Se o gestor indicava outro profissional para fornecer a listagem, um novo contato era feito com este profissional indicado (geralmente, da área administrativa do estabelecimento), para solicitar a lista de profissionais (médicos e enfermeiros) do estabelecimento, ou do turno e/ou departamento selecionados (como explicado na seção “Seleção da amostra” do “Relatório Metodológico”). Cada lista continha o nome e telefone(s) do profissional, informações que o identificavam de modo único. Após serem obtidas as listagens, se fosse o caso, os profissionais eram selecionados, também conforme o descrito no “Relatório Metodológico” e, então, contatados. Se não havia necessidade de seleção de profissionais, todos os listados eram inseridos no sistema. Assim, a última etapa do campo era:

- Agendar e realizar entrevista com médicos e enfermeiros. Todos os profissionais desses tipos selecionados na amostra eram contatados para a realização das entrevistas.

Tanto para gestores quanto para profissionais, recusas e dificuldades de contato com o respondente identificado ou selecionado impossibilitaram a obtenção de algumas entrevistas.

RESULTADO DO CAMPO

Ao todo, na pesquisa TIC Saúde de 2019, foram entrevistados 2.427 estabelecimentos, alcançando 63% da amostra planejada de 3.827 estabelecimentos. Destes, 2.027 eram elegíveis para a amostra de médicos e em 724 estabelecimentos houve ao menos uma entrevista com médico, o que resultou em 1.732 médicos entrevistados.

Da mesma maneira, 1.934 estabelecimentos eram elegíveis para a amostra de enfermeiros, sendo que em 993 deles houve pelo menos uma entrevista com enfermeiros, resultando em uma amostra de 2.458 enfermeiros entrevistados. O percentual de resposta para estabelecimentos, médicos e enfermeiros por variável de estratificação foi tal como disposto nas Tabelas 2, 3 e 4.

TABELA 2

TAXA DE RESPOSTA DE ESTABELECIMENTOS SEGUNDO REGIÃO, LOCALIZAÇÃO, ESFERA ADMINISTRATIVA E TIPO DE ESTABELECIMENTO

		Taxa de resposta
Região	Norte	58%
	Nordeste	58%
	Sudeste	62%
	Sul	75%
	Centro-Oeste	65%
Localização	Capital	54%
	Interior	68%
Esfera administrativa	Público	73%
	Privado	54%
Tipo de estabelecimento	Sem internação	64%
	Com internação (até 50 leitos)	65%
	Com internação (mais de 50 leitos)	69%
	Serviço de apoio à diagnose e terapia	49%

TABELA 3

TAXA DE RESPOSTA DE ESTABELECIMENTOS PARA ENFERMEIROS SEGUNDO REGIÃO, LOCALIZAÇÃO, ESFERA ADMINISTRATIVA E TIPO DE ESTABELECIMENTO

		Estabelecimentos elegíveis	Taxa de resposta
Região	Norte	310	52%
	Nordeste	417	51%
	Sudeste	410	45%
	Sul	432	57%
	Centro-Oeste	365	52%
Localização	Capital	501	34%
	Interior	1 433	58%
Esfera administrativa	Público	1 224	61%
	Privado	710	35%
Tipo de estabelecimento	Sem internação	724	63%
	Com internação (até 50 leitos)	597	54%
	Com internação (mais de 50 leitos)	613	35%
	Serviço de apoio à diagnose e terapia	–	–

TABELA 4

TAXA DE RESPOSTA DE ESTABELECIMENTOS PARA MÉDICOS SEGUNDO REGIÃO, LOCALIZAÇÃO, ESFERA ADMINISTRATIVA E TIPO DE ESTABELECIMENTO

		Estabelecimentos elegíveis	Taxa de resposta
Região	Norte	329	35%
	Nordeste	432	31%
	Sudeste	428	30%
	Sul	451	43%
	Centro-Oeste	387	40%
Localização	Capital	543	24%
	Interior	1 484	40%
Esfera administrativa	Público	1 233	42%
	Privado	794	26%
Tipo de estabelecimento	Sem internação	789	41%
	Com internação (até 50 leitos)	604	38%
	Com internação (mais de 50 leitos)	634	26%
	Serviço de apoio à diagnose e terapia	–	–

Processamento dos dados

PONDERAÇÃO DOS MÉDICOS

O universo de médicos considerado pela pesquisa foi definido como:

- Médicos não residentes nos estabelecimentos de saúde do tipo sem internação;
- Médicos não residentes nos estabelecimentos com internação de qualquer porte.

Foram excluídos do universo os estabelecimentos de serviço de apoio à diagnose e terapia.

O primeiro fator da construção de pesos dos médicos é o peso final dos estabelecimentos informantes da pesquisa. Ao todo, 2.027 – dos 2.427 estabelecimentos informantes da pesquisa – declararam possuir pelo menos um médico não residente e não ser um estabelecimento de serviço de apoio à diagnose e terapia. Desses, 724 tiveram alguma entrevista realizada com médicos.

A correção de não resposta para os estabelecimentos foi realizada por ajuste de um modelo logístico para previsão da probabilidade de resposta de cada estabelecimento. As variáveis que se mostraram determinantes para a resposta de médicos em um estabelecimento foram:

- Região;
- Esfera administrativa;
- Número de médicos que trabalham no estabelecimento em categorias;
- Tipo de estabelecimento;
- Localização.

O modelo logístico classificou corretamente 64,9% do total de registros.

PONDERAÇÃO DOS ENFERMEIROS

O universo de enfermeiros considerado pela pesquisa foi definido pelos profissionais que trabalham nos estabelecimentos de saúde do tipo sem internação e com internação de qualquer porte. Foram excluídos do universo os estabelecimentos de serviço de apoio à diagnose e terapia.

O primeiro fator da construção de pesos dos enfermeiros é o peso final dos estabelecimentos informantes da pesquisa. Ao todo, 1.934 – dos 2.427 estabelecimentos informantes da pesquisa – declararam possuir pelo menos um enfermeiro e não ser um estabelecimento de serviço de apoio à diagnose e terapia. Desses, 993 tiveram alguma entrevista realizada com enfermeiros. Para a correção de não resposta dos estabelecimentos, adotou-se o mesmo método aplicado a médicos – modelo logístico.

As variáveis que se mostraram determinantes para a resposta de enfermeiros em um estabelecimento foram:

- Região;
- Esfera administrativa;
- Número de enfermeiros que trabalham no estabelecimento em categorias;
- Tipo de estabelecimento;
- Localização.

O modelo logístico classificou corretamente em torno de 64,1% do total de registros.

ANÁLISE DOS RESULTADOS

PESQUISA
TIC SAÚDE

2019

Análise dos Resultados TIC Saúde 2019

No início de 2020, o mundo tomou conhecimento da COVID-19, doença respiratória aguda causada pelo novo coronavírus, denominado SARS-CoV-2. Identificada pela primeira vez em dezembro de 2019 na cidade de Wuhan, na região central da China, seu crescimento exponencial levou a Organização Mundial da Saúde (OMS) a declarar, em janeiro, que o surto do novo coronavírus deveria ser considerado uma Emergência de Saúde Pública de Importância Internacional (ESPII), o mais alto nível de alerta da organização. Em março, a COVID-19 passou a ser caracterizada como uma pandemia (Organização Mundial da Saúde [OMS], 2020). No mês de agosto do mesmo ano, a COVID-19 já estava presente em 188 países¹, instalando uma crise sanitária e humanitária de proporções inéditas, que levou ao acelerado crescimento de óbitos e à pressão sobre os sistemas de saúde em todo o mundo.

Diante desse contexto de pandemia, a adoção das tecnologias de informação e comunicação (TIC) tornou-se ainda mais essencial. O uso dos sistemas eletrônicos para registro de informações dos pacientes ampliou o compartilhamento e acesso imediato desses dados, possibilitando que os organismos responsáveis possam tomar decisões e coordenar ações de combate à pandemia (Organização Pan-Americana da Saúde [Opas], 2020a).

A disponibilidade de dados permite “uma compreensão mais rápida do comportamento de uma pandemia em uma determinada população, e assim, possibilita intervenções mais rápidas e abrangentes de contenção e/ou mitigação” (Opas, 2020a, p. 2). Ressalta-se que a disponibilidade de dados está diretamente vinculada à coleta e ao registro destes, já que só a completude, a segurança e a qualidade dos registros permitem análises que possam sustentar a tomada de decisão em saúde, com análise de tendências e padrões de incidência das doenças. No caso da COVID-19, o acesso

¹ Mais informações no painel de dados estatísticos da pandemia COVID-19 da Universidade Johns Hopkins. Recuperado em 15 de agosto, 2020, de <https://coronavirus.jhu.edu/map.html>

aos dados ajuda a entender as características específicas dos grupos mais afetados pela doença e os estratos mais vulneráveis da população e, com isso, possibilita planejar o direcionamento de recursos e as estratégias voltadas para a contenção da proliferação da doença (Opas, 2020b).

O uso de sistemas eletrônicos e a qualidade de registros também evidenciaram a importância de estudos em saúde digital e o grau de maturidade que os países conseguem atingir para troca de informações. No Brasil, os dados apresentados em edições anteriores da pesquisa TIC Saúde indicavam que a saúde digital mantinha uma tendência de expansão, por meio da ampliação da adoção das TIC nos estabelecimentos de saúde e da adaptação a novas formas de atendimento, cuidado e monitoramento da saúde do cidadão. Com o advento da pandemia COVID-19, tornou-se ainda mais relevante o acesso rápido a informações seguras e precisas em um cenário dinâmico de tomada de decisões sobre a saúde global. A utilização das TIC, nesse cenário, tem se mostrado fundamental ao conciliar agilidade, precisão e confiabilidade no compartilhamento de informações entre as redes pública e privada do sistema de saúde brasileiro, e entre os entes federativos. Dessa maneira, é urgente que os governos, em todas as esferas, repensem e ampliem o papel das TIC na área da saúde. Essas ferramentas se mostraram parte inerente da prevenção desta e de possíveis novas crises de saúde, seja ela causada por tipos de vírus desconhecidos ou por doenças negligenciadas.

Inúmeras ações envolvendo o uso de TIC foram desenvolvidas para prevenir e monitorar a expansão da pandemia no país. O alto potencial de propagação do vírus, a facilidade do contágio em espaços fechados e a necessidade de evitar a busca em massa por atendimentos em saúde – evitando que pacientes com outras doenças corressem o risco de se infectar com o novo coronavírus – fizeram com que a telessaúde se tornasse uma estratégia fundamental de cuidado, possibilitando que os cidadãos tenham acesso a informação adequada e qualificada sobre como proceder (Dorsey & Topol, 2020). Além disso, em casos de indivíduos com níveis de ansiedade elevados e/ou sintomas de COVID-19 leves ou moderados, o atendimento *on-line* representa uma importante alternativa para evitar o contágio e facilitar o isolamento social (Greenhalgh, Wherton, Shaw, & Morrison, 2020). Assim, a telessaúde, com uma ampla gama de tecnologias digitais e em suas múltiplas e diversas aplicações, mostrou grande potencial para ser utilizada como ferramenta no enfrentamento da pandemia COVID-19 (Caetano *et al.*, 2020).

No caso brasileiro, o governo federal autorizou, em caráter emergencial, por meio da Lei n. 13.989, de 15 de abril de 2020, o uso da telemedicina durante a pandemia, permitindo que médicos atendam seus pacientes por meio virtual. Essa medida também possibilitou que profissionais da saúde que fazem parte do grupo de risco da doença – com histórico de problemas de saúde pré-existent, mulheres grávidas e funcionários acima de 60 anos – pudessem continuar realizando atendimentos não presenciais. Em um momento em que diversos profissionais foram transferidos para a linha de frente do atendimento dos pacientes com COVID-19 e outros afastados por terem sido contaminados, e tendo em conta a dificuldade de ampliar a força de trabalho na saúde em um curto período de tempo para atender a expansão dessa nova demanda, o uso de tecnologias e da telemedicina proporcionou que os demais pacientes não ficassem desassistidos (Portnoy, Waller, & Elliott, 2020). Ressalta-se que no Brasil o uso da telemedicina ainda encontra barreiras para sua expansão devido às lacunas e desigualdades no acesso às TIC pelos estabelecimentos de saúde e pelos cidadãos.

Outras ações podem ser identificadas, nas esferas pública e privada, em relação à oferta de aplicativos que auxiliam os cidadãos na autoavaliação dos sintomas, reduzindo, assim, a procura por atendimento presencial no sistema de saúde – como é o caso do Coronavírus SUS (Ministério da Saúde [MS], 2020a). Recursos como Inteligência Artificial, técnicas de aprendizado de máquina e algoritmos preditivos têm sido utilizados para o monitoramento dos casos registrados com o intuito de que seja feito um rastreamento da difusão do vírus e uma busca ativa de pessoas possivelmente expostas a ele, além de serem utilizados para a previsão da disseminação da doença, o apoio no diagnóstico e no tratamento, a gestão de leitos e insumos hospitalares e o desenvolvimento de novos medicamentos e vacinas (Tunes, 2020).

Realizada em um momento imediatamente anterior à disseminação da pandemia no Brasil – julho de 2019 a fevereiro de 2020 – a pesquisa TIC Saúde 2019 apresenta dados que permitem o mapeamento do cenário da adoção e uso das TIC nos estabelecimentos de saúde brasileiros e sua apropriação por parte dos profissionais da área. O estudo apresenta um diagnóstico da situação da saúde digital no país por meio de dados sobre a infraestrutura TIC nos estabelecimentos de saúde, a disponibilização de sistemas de saúde para registro das informações sobre os pacientes e seus níveis de complexidade, e indicadores sobre segurança e privacidade dos dados clínicos e uso de telessaúde.

Nesta edição, a “Análise dos Resultados” está estruturada nas seguintes seções:

- Infraestrutura e uso das TIC nos estabelecimentos de saúde;
- Gestão e governança de TI;
- Registro eletrônico em saúde e troca de informações;
- Serviços *on-line* oferecidos ao paciente e telessaúde;
- Adoção das TIC nas Unidades Básicas de Saúde;
- Acesso e uso das TIC pelos profissionais de saúde;
- Considerações finais: agenda para as políticas públicas.

Infraestrutura e uso das TIC nos estabelecimentos de saúde

A disponibilização de computadores e acesso à Internet em todos os estabelecimentos de saúde brasileiros é condição necessária para uma efetiva ampliação da saúde digital no país. A pesquisa TIC Saúde vem apontando, desde 2013, um aumento da presença de computadores e Internet nos estabelecimentos de saúde brasileiros, sendo que entre estabelecimentos com internação e os que prestam serviços de apoio à diagnose e terapia essa presença atingiu a universalização em 2019. Já entre os estabelecimentos sem internação, 95% tinham computadores e 91% tinham acesso à Internet. Esse resultado indica um déficit: cerca de 4,4 mil estabelecimentos sem computadores e 8,2 mil sem acesso à Internet.

As disparidades no acesso à infraestrutura TIC são marcantes entre as esferas administrativas e as regiões geográficas do país. Conforme aponta a Tabela 1, a estimativa é de que 50 mil estabelecimentos públicos (92%) tinham computadores e 46,3 mil (85%) tinham acesso à Internet, enquanto nos estabelecimentos privados

esse acesso foi universal. Quanto às diferenças regionais de acesso a essas tecnologias, assim como identificado em outras pesquisas do Cetic.br², a TIC Saúde 2019 mostrou que, enquanto 99% dos estabelecimentos localizados na região Sudeste utilizavam computadores e 98% tinham acesso à Internet, na região Norte a proporção caía para 92% dos estabelecimentos utilizando computadores e 82% com acesso à Internet, número próximo ao da região Nordeste, em que 90% utilizaram computadores e 83% tiveram acesso à Internet. Neste último caso, os dados da Tabela 1 indicam que, em um total de 30,7 mil estabelecimentos de saúde localizados no Nordeste, 2,8 mil não tinham computador e 4,9 mil não tinham acesso à Internet.

TABELA 1

ESTABELECIMENTOS DE SAÚDE QUE UTILIZARAM COMPUTADOR E INTERNET (2019)*Total de estabelecimentos de saúde (%)*

Tipos de estabelecimentos		Utilizou computador		Utilizou Internet	
		Sim	Não	Sim	Não
TOTAL		105 157	4 483	101 400	8 464
ESFERA ADMINISTRATIVA	Público	50 063	4 342	46 306	8 099
	Privado	55 094	141	55 094	365
REGIÃO	Norte	6 608	562	5 884	1 286
	Nordeste	27 880	2 835	25 776	5 163
	Sudeste	43 315	461	42 780	996
	Sul	18 161	398	17 956	603
	Centro-Oeste	9 194	226	9 004	416
TIPO DE ESTABELECIMENTO	Sem internação	83 837	4 420	80 087	8 394
	Com internação (até 50 leitos)	4 798	39	4 791	47
	Com internação (mais de 50 leitos)	2 792	0	2 792	0
	Serviço de apoio à diagnose e terapia	13 730	24	13 730	24
LOCALIZAÇÃO	Capital	24 368	78	24 294	152
	Interior	80 790	4 404	77 106	8 311

² Em 2019, a região Nordeste foi a que teve menor quantidade de domicílios conectados à Internet (65%) e a Sudeste a maior quantidade (75%). A região Centro-Oeste tinha 70%; Norte com 72% e Sul com 73% (Comitê Gestor da Internet no Brasil [CGI.br], 2020c).

Em relação aos tipos de conexão à Internet utilizados por esses estabelecimentos, observa-se, ao longo da série histórica da pesquisa, o uso crescente da conexão via cabo ou fibra ótica: de 65% em 2015 para 86% em 2019. Assim, esse tipo de conexão – uma tecnologia que permite maior velocidade de acesso com menor latência – passou a ser a mais utilizada para o acesso à Internet entre todos os tipos de estabelecimentos de saúde. Conforme indicado no Gráfico 1, desde 2015 observa-se aumento na proporção dos estabelecimentos que acessaram a Internet por conexão via cabo ou fibra ótica, enquanto a conexão via DSL apresenta tendência de diminuição desde 2018, chegando a 43% em 2019.

Entre as regiões geográficas, o maior aumento das conexões via cabo ou fibra ótica foi verificado na região Nordeste: passou de 57%, em 2015, para 91%, em 2019. Na região Sul, a alteração foi de 58% para 82%, no Sudeste, de 74% para 86%, e no Centro-Oeste, de 58% para 77% dos estabelecimentos de saúde com esse tipo de conexão. Na região Norte, a proporção permaneceu estável, com cerca de 73% dos estabelecimentos com conexão via cabo ou fibra ótica no mesmo período.


Apesar do avanço citado, os estabelecimentos de saúde públicos (80%) e os localizados em municípios do interior (84%) contaram em menor proporção com a conexão via cabo ou fibra ótica do que os estabelecimentos privados (90%) e os localizados em capitais (92%). Os demais tipos de conexões banda larga também foram mais frequentes entre os estabelecimentos privados e os localizados em capitais, com exceção da conexão via rádio, que ainda é mais comum entre os estabelecimentos públicos (18%) e os localizados no interior (15%).

De forma correlata à tendência de aumento da disponibilidade de dispositivos móveis nos estabelecimentos de saúde, principalmente nas Unidades Básicas de Saúde (UBS), é possível observar uma maior proporção daqueles que utilizaram conexão móvel via *modem* ou *chip* 3G ou 4G, chegando a 39% dos estabelecimentos de saúde em 2019. Os dados indicam que esse tipo de conexão é complementar às demais, visto que menos de 2% dos estabelecimentos tinham exclusivamente conexões móveis.

A ampliação no uso de conexões móveis pode estar associada ao aumento de aplicativos disponibilizados pelo Departamento de Informática do Sistema Único de Saúde (Datasus). Entre os aplicativos, estão o MedSUS que apresenta a lista de medicamentos indicados pelo SUS; os módulos para gestores como e-SUS Gestor e o e-Gestor AB para a Atenção Básica; e o próprio aplicativo para usuários – Meu digiSUS –, que disponibiliza informações pessoais e clínicas presentes no Cadastro Nacional de Usuários do SUS, no Portal de Saúde do Cidadão e no Cadastro Nacional de Estabelecimentos de Saúde (CNES).³

³ Ver mais informações no *website* do Datasus. Recuperado em 15 agosto, 2020, de <https://datasus.saude.gov.br/wp-content/uploads/2019/08/Catalogo-de-Produtos-DATASUS.pdf>

GRÁFICO 1

ESTABELECIMENTOS DE SAÚDE, POR TIPO DE CONEXÃO À INTERNET (2019)*Total de estabelecimentos de saúde que utilizaram a Internet nos últimos 12 meses (%)*

A velocidade máxima para *download* da conexão principal dos estabelecimentos de saúde também aumentou nos últimos anos. Em 2019, 32% tinham contratado conexões de até 10 Mbps, uma diminuição de quatro pontos percentuais em relação a 2018. Já o percentual daqueles com velocidade acima de 100 Mbps passou de 4%, em 2018, para 11%, em 2019. Essa mesma tendência foi verificada em outras instituições públicas e privadas. Em 2019, 17% das empresas brasileiras tinham conexões com velocidade acima de 100 Mbps – um aumento de 12 pontos percentuais em relação a 2015 (CGI.br, 2020a). Entre as escolas urbanas, 17% apresentavam conexões de 51 Mbps ou mais em 2019, 15 pontos percentuais a mais do que em 2015 (CGI.br, 2020b).


Apesar dos avanços quanto à velocidade da conexão nos estabelecimentos de saúde, verificou-se disparidades de acordo com a esfera administrativa e o tipo de estabelecimento, sendo que as velocidades mais altas estão concentradas nos estabelecimentos privados e naqueles com internação e mais de 50 leitos, conforme o Gráfico 2. Em relação aos estabelecimentos públicos, quase metade dos gestores (46%) não souberam responder, isto porque, principalmente no caso das UBS que integram o grupo dos estabelecimentos sem internação, esses serviços são em geral contratados pelas secretarias de saúde.

Entre os que possuem internação e mais de 50 leitos (56%) e os serviço de apoio à diagnose e terapia (SADT) (41%), foi mais frequente a contratação de conexões entre 10 e 100 Mbps, se comparados ao total de estabelecimentos brasileiros (30%). Apesar dessas diferenças, houve aumento significativo na proporção de estabelecimentos sem internação e com até 50 leitos que contrataram conexões com velocidades na faixa acima de 100 Mbps. Nos que têm até 50 leitos, esse percentual passou de 5% para 11%, entre 2018 e 2019. Já naqueles sem internação, passou de 3% para 10%.

GRÁFICO 2

ESTABELECIMENTOS DE SAÚDE, POR FAIXA DE VELOCIDADE MÁXIMA PARA DOWNLOAD DA PRINCIPAL CONEXÃO (2019)

Total de estabelecimentos de saúde que utilizaram a Internet nos últimos 12 meses (%)



Aproximadamente metade dos gestores avaliaram que os equipamentos de TI disponíveis eram novos e atualizados (52%) e que a conexão de Internet era adequada às necessidades do estabelecimento (50%). Essa percepção melhorou nos últimos anos, mas ainda foi mais frequente entre gestores dos estabelecimentos privados: em 2019, 36% dos gestores dos estabelecimentos públicos e 68% dos privados concordaram que os equipamentos eram novos e atualizados, um aumento de cinco e dez pontos percentuais, respectivamente, em relação ao ano anterior. Quanto à conexão de Internet, 31% dos gestores dos estabelecimentos públicos e 67% dos privados afirmaram ser adequada às necessidades do estabelecimento. Nesse quesito, houve melhora da percepção apenas entre os gestores públicos, registrando um aumento de cinco pontos percentuais em relação a 2018.

Essa diferença de percepção também se observa em relação aos gestores de estabelecimentos localizados no interior e nas capitais: enquanto 47% daqueles afirmaram que os equipamentos eram novos e atualizados, 68% dos gestores dos estabelecimentos das capitais concordaram com essa afirmação, representando um aumento de sete e nove pontos percentuais, respectivamente, sobre os dados de 2018. Quanto à conexão à rede ser adequada às demandas dos estabelecimentos, essa proporção chegou a 47% entre os gestores do interior e a 59% entre os gestores dos estabelecimentos de saúde das capitais, não tendo uma variação significativa em relação ao ano anterior.

Gestão e governança de TI

A presença de uma área ou departamento de TI no estabelecimento de saúde, aliada a profissionais capacitados e dedicados a gerir os recursos TIC, é importante para que sejam elaboradas estratégias que visem o melhor desenvolvimento, adaptação e apropriação das TIC nos estabelecimentos de saúde e pelos profissionais. Uma governança em TI estruturada tem papel estratégico no desenvolvimento de processos orientados aos propósitos do estabelecimento, com base em mudanças de processos e entrega de tecnologia. No entanto, muitos gestores ainda têm dificuldades em adotar uma visão mais ampla sobre o papel da TI, por esta não ser a atividade-fim da organização (Santos & Terra, 2018). É fundamental, assim, que o uso das TIC seja entendido como recurso estratégico e não como serviço.

A TIC Saúde 2019 aponta estabilidade na proporção média de estabelecimentos de saúde que contavam com essa área (27% em 2019 e 25% em 2018). Pode-se inferir que nas organizações a área de TI ainda é vista como sendo um recurso para prestação de serviço e garantia de infraestrutura para atingir a maturidade digital. A presença desse departamento se mostrou desigual entre as esferas administrativas e os diferentes tipos de estabelecimentos de saúde brasileiros. Um percentual menor de estabelecimentos públicos (14%) possuía departamento de TI em relação aos privados (38%). Enquanto a maioria dos estabelecimentos com internação e mais de 50 leitos contava com uma área ou departamento de TI (80%), essa proporção era bem mais baixa entre os demais, com o menor percentual para estabelecimentos sem internação (23%).

Entre os estabelecimentos de saúde que possuíam uma área ou departamento de TI, a maioria tinha entre um e três funcionários nesta área (76%), percentual que não variou significativamente quanto à esfera administrativa. Entre os que apontaram ter mais funcionários ligados à área ou departamento de TI, 22% dos estabelecimentos públicos e 14% dos privados indicaram ter entre quatro e dez funcionários, e apenas 2% dos públicos e 9% dos privados apontaram ter mais de dez pessoas trabalhando nessa área.

Apenas dois em cada dez desses estabelecimentos com área de TI tinham um profissional com formação na área da saúde em seus respectivos departamentos de TI, resultado que não apresentou diferenças entre os estabelecimentos públicos e privados. A presença de profissionais com formação em saúde nesses departamentos é bastante estratégica, uma vez que possuem competências para compreender as demandas e necessidades dos profissionais de saúde e pacientes, auxiliando no processo de desenvolvimento e implementação das TIC no setor. A literatura aponta que a presença de um profissional de saúde com formação em informática em saúde pode tornar a equipe mais produtiva, aumentando as habilidades e definindo as expectativas claras dos papéis de cada um. Por ser uma área interprofissional e multiprofissional, o conhecimento dos processos e fluxos em saúde agiliza os projetos e colabora para maior assertividade (Holden, Binkheder, Patel, & Viernes, 2017).


Em relação ao suporte técnico na área de TI, 21% dos estabelecimentos de saúde brasileiros tinham uma equipe interna para a realização desse serviço, enquanto 39% deles tinham um prestador de serviço contratado pelo próprio estabelecimento. O Gráfico 3 evidencia as diferenças do suporte técnico entre as redes pública e privada e os tipos de estabelecimentos. Em 65% dos estabelecimentos públicos, o serviço

foi realizado por um prestador contratado pela secretaria de saúde, percentual que se manteve estável em relação ao ano anterior. Já nos estabelecimentos privados, 69% tiveram esse serviço realizado por um prestador contratado pelo próprio estabelecimento em 2019, contra 78% em 2018. Também houve acréscimo de cinco pontos percentuais em relação ao ano anterior quanto ao número de estabelecimentos privados em que o suporte foi realizado por uma equipe interna. Entre os tipos de estabelecimentos destaca-se que 67% dos com internação e mais de 50 leitos possuíam uma equipe interna para a realização do suporte técnico em TI.

GRÁFICO 3

ESTABELECIMENTOS DE SAÚDE, POR PRINCIPAL RESPONSÁVEL PELO SUPORTE TÉCNICO EM INFORMÁTICA (2019)

Total de estabelecimentos de saúde que utilizaram a Internet nos últimos 12 meses (%)



Em relação ao debate sobre segurança e privacidade da informação, o adiamento da entrada em vigor da Lei Geral de Proteção de Dados Pessoais (LGPD), por conta da pandemia COVID-19, acabou por ampliar o prazo para que o setor da saúde, assim como os demais setores que coletam e/ou armazenam informações pessoais, se adequasse às diretrizes estipuladas pela nova lei.⁴

A LGPD visa a assegurar o direito à privacidade e à proteção dos dados pessoais. Em vista disto, são necessárias adequações de todas as instituições que lidam com dados pessoais, em especial no setor da saúde, tanto na área de pesquisas clínicas quanto no uso de Inteligência Artificial e *Big Data*. Além disso, dados armazenados pelos prontuários eletrônicos dos pacientes são caracterizados como sensíveis, podendo ser utilizados de forma discriminatória e, portanto, carecem de proteção especial (Guanaes, 2018;

⁴ A vigência da Lei Geral de Proteção de Dados Pessoais – LGPD foi adiada pela Medida Provisória n. 959, de 29 de abril de 2020. Ver mais informações sobre a tramitação no site do Congresso Nacional. Recuperado em 15 agosto, 2020, de <https://www.congressonacional.leg.br/materias/medidas-provisorias/-/mpv/141753>

Spagnoli & Soares, 2019; Sarlet & Molinaro, 2019; Pinheiro, 2018; Siqueira & Hoch, 2019). Entre as diversas exigências da lei, estão a adoção de medidas de segurança da informação que garantam a proteção dos dados pessoais contra acessos não autorizados e situações acidentais ou ilícitas, bem como a criação de boas práticas de governança que estabeleçam procedimentos, normas de segurança, ações educativas e mitigação de riscos no tratamento desses dados.

A pesquisa TIC Saúde 2019 revela os desafios para a adaptação de parte dos estabelecimentos de saúde tanto em relação à normatização e regulamentação de políticas de segurança da informação dos pacientes quanto em relação às ferramentas de segurança adotadas. Diante da recomendação da LGPD⁵ sobre a formulação de regras de boas práticas e de governança, incluindo normas e padrões de segurança da informação, os dados da pesquisa indicam uma lacuna na adoção de normas específicas para o tratamento e acesso aos dados dos seus pacientes entre os estabelecimentos de saúde. Em 2019, cerca de um terço (31%) dos estabelecimentos de saúde tinham um documento que definia uma política de segurança da informação. Em relação a 2018, houve aumento nessa proporção entre aqueles localizados na região Sudeste (passando de 22% para 43%) e nos municípios do interior (de 18% em 2018, para 27% em 2019). Nos demais tipos de estabelecimentos, essa proporção se manteve estável. Além disso, verificou-se que uma maior parcela de estabelecimentos com internação e mais de 50 leitos (56%), estabelecimentos privados (44%) e SADT (37%) estava se adequando à recomendação da lei com a elaboração de uma política de segurança da informação mais explícita. Entre os estabelecimentos públicos, apenas 16% possuía um documento desse tipo.

Quando analisadas as ferramentas de segurança da informação utilizadas pelos estabelecimentos de saúde, verificou-se uma variação positiva no percentual de estabelecimentos que possuíam biometria para acesso ao sistema eletrônico – passando de 8%, em 2018, para 16%, em 2019 – e uma diminuição da disponibilidade de certificado digital – 35%, em 2019, contra 45%, em 2018. Entre os tipos de estabelecimentos, aqueles com mais de 50 leitos de internação e os SADT foram os que apresentaram melhores resultados na adoção de ferramentas de segurança da informação, inclusive das ferramentas mais sofisticadas de proteção dos dados como criptografia, certificado digital e assinatura eletrônica (Gráfico 4).

A partir desta edição da pesquisa, além das ferramentas de proteção aos dados já investigadas nas edições anteriores, foram acrescentadas duas outras: *data loss protection/prevention* (proteção contra vazamento) e duplo fator de autenticação. No total, 22% dos estabelecimentos de saúde utilizaram a proteção contra vazamento, sendo que o maior percentual foi nos SADT (29%) e nos estabelecimentos com mais de 50 leitos (23%), além de estar presente em 29% dos estabelecimentos privados e em 14% dos públicos. Essa ferramenta é utilizada no monitoramento de ocorrências que podem ocasionar vazamentos de informações, diagnosticando e corrigindo vulnerabilidades do sistema. Dessa forma, atua preventivamente para que nenhum dado sensível seja indevidamente acessado e compartilhado, tanto por alguém que trabalhe no estabelecimento quanto por ameaças externas de roubo de dados.


⁵ Artigo 50 da Lei Geral de Proteção de Dados (LGPD).

Já o duplo fator de autenticação esteve presente em apenas 7% dos estabelecimentos. Essa ferramenta fornece mais segurança no acesso ao sistema eletrônico, ao exigir a autenticação em duas etapas. Os sistemas variam, mas geralmente solicitam uma senha e um segundo fator de autenticação, que pode ser uma confirmação por meio de código obtido de um aplicativo ou mensagem de SMS. Esse recurso dificulta o acesso sem autorização aos sistemas eletrônicos dos estabelecimentos de saúde.

GRÁFICO 4

ESTABELECIMENTOS DE SAÚDE, POR TIPO DE FERRAMENTA DE SEGURANÇA DA INFORMAÇÃO UTILIZADA (2019)

Total de estabelecimentos de saúde que utilizaram a Internet nos últimos 12 meses (%)



A percepção de segurança e privacidade dos sistemas foi consideravelmente menor entre os gestores de estabelecimentos públicos. Para 45% deles os sistemas eletrônicos disponíveis eram seguros e garantiam a confidencialidade e privacidade das informações, percentual bastante inferior ao verificado entre os gestores de estabelecimentos privados (82%). Quando os dados são examinados por tipo de estabelecimento, os gestores dos SADT (82%) e dos que possuem internação com mais de 50 leitos (68%) foram os que mais concordam com essa afirmação. Nos estabelecimentos com internação e menos de 50 leitos (48%) e sem internação (61%), os gestores apresentaram uma avaliação mais crítica.

Registro eletrônico em saúde e troca de informações

O registro eletrônico em saúde é uma ferramenta que possibilita aos estabelecimentos monitorarem e acessarem de forma rápida e padronizada os dados dos pacientes. O registro eletrônico permite integrar o cuidado ao paciente entre os membros da equipe em um estabelecimento específico (integração horizontal) e entre os prestadores de atenção à saúde nos diferentes níveis de atendimento – primário, secundário e terciário (integração vertical). Ao mesmo tempo, quanto mais complexo o sistema eletrônico no estabelecimento, melhor sua capacidade de reduzir a fragmentação na prestação do cuidado, favorecendo a qualidade e eficiência, além de reduzir lacunas no atendimento (Janett & Yeracaris, 2020). No contexto de pandemia, os registros dos pacientes passam a ter maior importância em termos de saúde pública (Stoeger & Schmidhuber, 2020) e dados sobre diagnósticos e medicamentos prescritos podem ser utilizados para identificar pessoas em grupos de risco da COVID-19, por exemplo.

A maior disponibilidade de dados dos pacientes em formato eletrônico é de grande relevância para a tomada de decisão e continuidade do cuidado nos setores público e privado, principalmente com troca de informações entre as duas esferas⁶. No contexto da pandemia COVID-19, o Ministério da Saúde segue o desenvolvimento da Rede Nacional de Dados em Saúde (RNDS), uma plataforma que permite aos sistemas de prontuários eletrônicos se conectarem e trocarem informações sobre a saúde de um paciente. A plataforma tem sido utilizada na estratégia de combate e controle da pandemia no país, visto que todos os laboratórios públicos e privados passaram a ser obrigados a notificar o Ministério da Saúde, por meio da RNDS, em até 24 horas após os resultados de exames para a COVID-19.⁷

Os dados da pesquisa TIC Saúde 2019 mostram uma ampliação na adoção de sistemas eletrônicos nos estabelecimentos de saúde. Em 2019, 82% deles contavam com sistemas eletrônicos para registro das informações dos pacientes, proporção que era de 73% em 2018. A lacuna dos que não tinham um sistema eletrônico é estimada em cerca de 18 mil estabelecimentos brasileiros de saúde.

Enquanto nove em cada dez estabelecimentos privados (88%) contavam com sistemas eletrônicos para registro de informações de seus pacientes, essa proporção foi de 74% entre os da esfera pública. Isso significa que, em 2019, esse recurso não estava disponível para cerca de 12 mil estabelecimentos de saúde públicos (Gráfico 5). Em termos regionais, aqueles localizados nas regiões Sul (90%) e Sudeste (83%) apresentaram patamares superiores de adoção desses sistemas, quando comparados aos das regiões Centro-Oeste (78%), Nordeste (77%) e Norte (74%). A presença de sistemas eletrônicos também se mostrou desigual entre estabelecimentos localizados em municípios do interior (79%) na comparação aos das capitais (92%).

⁶ Argumento apresentado por Jackson Barros, diretor do Datasus, durante apresentação *on-line* no *webinar* "COVID-19: a importância da utilização de dados na tomada de decisão na saúde", organizado pela Associação Nacional de Hospitais Privados (Anahp), em junho de 2020. Recuperado em 15 agosto, 2020, de <https://www.anahp.com.br/noticias/noticias-anahp/especialistas-discutem-a-importancia-do-uso-de-dados-na-saude-brasileira-em-tempos-de-pandemia/>


⁷ Para mais informações, ver as páginas eletrônicas do Ministério da Saúde. Recuperado em 15 agosto, 2020, de <https://rn.ds.saude.gov.br/> e de <https://saudedigital.saude.gov.br/material-de-apoio/>

Quanto ao tipo de estabelecimento, os com internação acima de 50 leitos e os SADT tinham em maior proporção sistemas eletrônicos para registro das informações de seus pacientes (91% em ambos os casos), sendo que os que possuem internação e menos de 50 leitos tiveram a menor proporção (67%).

GRÁFICO 5

ESTABELECIMENTOS DE SAÚDE, POR EXISTÊNCIA DE SISTEMA ELETRÔNICO PARA REGISTRO DAS INFORMAÇÕES DOS PACIENTES (2019)

Total de estabelecimentos de saúde que utilizaram a Internet nos últimos 12 meses (%)



O aumento da presença de sistemas eletrônicos para registro de informações dos pacientes se reflete na maneira como são armazenadas essas informações, física ou digital. Em relação a 2018, houve redução na proporção de estabelecimentos que mantinham as informações dos prontuários apenas em papel, passando de 27% para 18%. Paralelamente, cresceu a parcela dos que mantiveram essas informações tanto em papel quanto em formato eletrônico, passando de 54% para 64%. O percentual de estabelecimentos que mantinha as informações apenas em formato eletrônico não teve alteração em relação à pesquisa anterior (18%).

A redução dos que mantinham as informações dos pacientes apenas em papel ocorreu principalmente entre os estabelecimentos públicos (de 38%, em 2018, para 28%, em 2019), nos sem internação (de 30% para 19%) e nos localizados em municípios do interior (de 32% para 20%). No âmbito da gestão federal, o tema integra a Estratégia de Saúde Digital no Brasil, iniciativa do Ministério da Saúde que visa a fortalecer a rede

de atenção em saúde por meio da informatização da gestão e da assistência em saúde, com foco na atenção primária, prevendo ações como a definição e a implantação dos sistemas e serviços de e-Saúde integrados ao SUS (Ministério da Saúde [MS], 2017).

Apesar dos avanços, o processo de informatização de dados dos pacientes no setor público permanece aquém do necessário. Se comparados aos privados, a parcela de estabelecimentos públicos que mantinham tais informações apenas em papel foi quase o triplo – 28% contra 9% entre os privados. Nestes últimos, cerca de um quarto (23%) mantinha, em 2019, as informações de seus pacientes somente em formato eletrônico, contra apenas 12% entre os estabelecimentos públicos.

Verificou-se, ainda, uma tendência de aumento na disponibilização de informações nos registros eletrônicos em saúde. Os aumentos mais significativos foram os de dados cadastrais do paciente (89% em 2019, 10 pontos percentuais a mais do que em 2018); de principais motivos que levaram o paciente ao atendimento ou consulta (64% em 2019, contra 50% na edição anterior); e os de admissão, transferência e alta do paciente (56% em 2019, enquanto estava disponível em um terço dos estabelecimentos em 2018). Essa tendência de informatização da coleta e uso das informações dos pacientes ocorreu entre os estabelecimentos públicos, os sem internação e os localizados em municípios do interior, os mesmos estratos que contaram com aumentos consideráveis na adoção de sistemas eletrônicos.

Os estabelecimentos com internação e mais de 50 leitos foram os que tiveram maior disponibilidade dos dados dos pacientes em formato eletrônico, visto que todos os tipos estavam disponíveis em mais da metade deles, com destaque para os dados cadastrais, as informações de admissão, transferência e alta e os principais motivos que levaram o paciente ao atendimento ou consulta. Os estabelecimentos sem internação apresentaram maior disponibilização desses dados em relação ao ano anterior.

TABELA 2

ESTABELECIMENTOS DE SAÚDE, POR TIPO DE DADO SOBRE O PACIENTE DISPONÍVEL ELETRONICAMENTE (2019)*Total de estabelecimentos de saúde que utilizaram a Internet nos últimos 12 meses (%)*

Tipos de Dados	Total	Sem internação	Com internação (até 50 leitos)	Com internação (mais de 50 leitos)	Serviço de apoio à diagnose e terapia
Dados cadastrais do paciente	89	89	72	90	90
Histórico ou anotações clínicas sobre o atendimento ao paciente	65	67	49	75	58
Principais motivos que levaram o paciente ao atendimento ou consulta	64	67	61	82	48
Diagnóstico, problemas ou condições de saúde do paciente	64	66	50	77	53
Resultados de exames laboratoriais do paciente	61	59	53	75	74
Admissão, transferência e alta do paciente	56	58	65	90	34
Alergias do paciente	54	56	44	71	41
Lista de medicamentos prescritos ao paciente	53	57	45	73	29
Anotações de enfermagem sobre o paciente	51	56	42	70	25
Vacinas administradas ao paciente	46	52	32	51	16
Sinais vitais do paciente	45	47	47	70	24
Laudo de exames radiológicos do paciente	38	38	38	68	31
Imagens de exames radiológicos do paciente	24	22	34	65	27


Em relação às funcionalidades que compõem os sistemas eletrônicos, o Gráfico 6 apresenta as que estavam disponíveis em maior percentual de estabelecimentos, de acordo com o tipo. Em geral, funcionalidades de natureza administrativa, como agendar consultas e fazer pedidos de exames, foram as mais disponíveis. No entanto, mesmo dentro desse grupo, funcionalidades mais complexas, como listar informações de um paciente ou de todos os pacientes e listar informações sobre exames e medicamentos, estavam presentes em apenas um quarto dos estabelecimentos de saúde.

As funcionalidades relacionadas ao suporte à decisão – importantes para que os profissionais recebam informações sobre os procedimentos recomendados nos atendimentos que realizam, auxiliando na decisão sobre diagnósticos e tratamentos – estavam disponíveis em um menor número de estabelecimentos. Dentro desse grupo, as mais presentes foram as diretrizes clínicas, práticas recomendadas ou protocolos (27%) e alertas e lembretes sobre alergias a medicamentos (24%). Todas as demais funcionalidades investigadas pela pesquisa estiveram presentes em aproximadamente um quinto dos estabelecimentos de saúde brasileiros. Vale ressaltar que sistemas de apoio à decisão necessitam que o registro do paciente seja realizado. É necessário, portanto, que haja informação prévia sobre o paciente para que o uso de funcionalidades como alertas, lembretes e guias de conduta sejam sugeridos para melhor resultado do cuidado. Tais sistemas devem estar integrados ao registro ou prontuário para aderência e uso pelo profissional de saúde (Sutton *et al.*, 2020).

Também foi menos frequente a disponibilização de funcionalidades que permitem a troca de informações entre sistemas eletrônicos de diferentes estabelecimentos. A viabilidade dessa troca é importante para que seja consultado, modificado ou garantido o tratamento oferecido quando da necessidade da transferência do paciente de um estabelecimento para outro, principalmente entre os diferentes níveis da atenção à saúde, conforme o grau da gravidade da situação do paciente. As funcionalidades de troca de informações mais comumente disponibilizadas foram o envio ou recebimento de encaminhamentos de forma eletrônica (38%) e de relatórios de assistência prestada ao paciente no momento em que recebeu alta ou foi encaminhado a outro estabelecimento (34%).

Entre os estabelecimentos públicos, os maiores aumentos, nos últimos anos, ocorreram em funcionalidades como listar todos os resultados de exames laboratoriais de um paciente (passou de 17%, em 2016, para 41%, em 2019), listar todos os pacientes que fazem uso de uma medicação (de 18%, em 2016, para 40%, em 2019) e realizar prescrição médica (de 29% para 51% no mesmo período). Já em relação aos estabelecimentos privados, as funcionalidades com maior crescimento entre 2016 e 2019 foram: pedir exames de imagem (de 33% para 51%), pedir exames laboratoriais (de 36% para 51%) e agendar consultas e exames (de 53% para 67%).

GRÁFICO 6

ESTABELECIMENTOS DE SAÚDE, POR FUNCIONALIDADES ELETRÔNICAS DISPONÍVEIS EM SISTEMA (2019)*Total de estabelecimentos de saúde que utilizaram a Internet nos últimos 12 meses (%)*

Considerando a necessidade de troca de informações sobre os pacientes, em especial no sistema público de saúde, a pesquisa TIC Saúde investiga, desde 2018, se os sistemas eletrônicos presentes nos estabelecimentos recebem ou enviam informações diretamente para outros sistemas eletrônicos da rede de atenção à saúde básica, especializada ou hospitalar. Esse indicador pretende mapear a presença de padrões mínimos de interoperabilidade⁸. Assim, em 2019, 19% dos estabelecimentos de saúde brasileiros recebiam ou enviavam informações de seus sistemas eletrônicos para outros sistemas da rede de atenção à saúde, proporção que se manteve estável em relação a 2018. Os estabelecimentos públicos (25%) e os com mais de 50 leitos de internação (31%) foram os que mais disponibilizavam a possibilidade de realizar esse tipo de troca de informações entre os sistemas.

Serviços on-line oferecidos ao paciente e telessaúde

No Brasil, o número de usuários de Internet aumentou nos últimos anos em todas as classes sociais. Em 2019, 74% da população brasileira com 10 anos e mais acessava a Internet, com maior procura por informações em *websites* e redes sociais (CGI.br, 2020c). A pandemia COVID-19 fez com que a busca por informações sobre saúde se

⁸ A Estratégia de Saúde Digital indica, a partir de uma análise geral, que existem projetos e iniciativas importantes nos setores público e privado, mas que há "fraco alinhamento entre estas iniciativas" e faz uma análise mais detalhada para os registros eletrônicos em saúde (RES), telessaúde, apoio à mobilidade, gestão do fluxo de pacientes, gestão e operação das unidades de saúde e gestão integrada do SUS (MS, 2017, p. 51).

intensificasse. Segundo dados do Painel TIC COVID-19, realizado em julho de 2020, 72% dos usuários de Internet de 16 anos ou mais procuraram informações relacionadas à saúde, um acréscimo considerável se comparado à mesma população de referência em 2019, em que 55% fez esse tipo de busca por informação (CGI.br, 2020d).

Em um momento de situação emergencial na área da saúde, como em casos de surtos, epidemias e pandemias, a comunicação é essencial e o acesso a informações seguras e precisas contribui para o enfrentamento da crise tanto por parte dos órgãos responsáveis quanto pela população (MS, 2020b). Assim, a Internet também é, cada vez mais, um importante canal de comunicação entre os estabelecimentos de saúde e os usuários, principalmente na divulgação de informações sobre prevenção e cuidados em saúde. É possível encontrar na Internet os dias de atendimento médico de cada especialidade, a forma de distribuição de medicamentos, informações sobre marcação de consultas e questões relacionadas a farmácias e laboratórios. Com a disponibilização dessas informações *on-line*, evita-se o deslocamento dos usuários. A maior presença dos estabelecimentos de saúde na Internet também possibilitaria uma ampliação da oferta de informações mais precisas, seguras e confiáveis para os cidadãos e auxiliaria no combate à desinformação no contexto da pandemia (Sousa, Raasch, Soares, & Ribeiro, 2020).


Apesar de ainda baixa, a presença dos estabelecimentos de saúde na Internet cresceu ao longo dos últimos anos: de 2015 a 2019, aumentou de 39% para 45% a proporção dos estabelecimentos que possuíam um *website*, bem como subiu de 33% para 46% os que tinham perfil ou conta em redes sociais *on-line*. Nesse mesmo período, diminuiu a parcela dos estabelecimentos que não estavam presentes em nenhuma dessas plataformas *on-line*, diminuindo de 48%, em 2015, para 36%, em 2019.

Essa presença na Internet varia bastante conforme os diferentes perfis de estabelecimentos de saúde. Os privados (50%), os com internação e mais de 50 leitos (51%) e os SADT (48%) foram os mais presentes *on-line*, tanto por meio de *websites* quanto por perfis em redes sociais (Gráfico 7). Ao mesmo tempo, mais da metade dos estabelecimentos públicos (57%) e cerca de quatro em cada dez dos que não possuem internação (39%) e com internação até 50 leitos (44%) não estavam presentes em nenhuma dessas plataformas.

GRÁFICO 7

ESTABELECIMENTOS DE SAÚDE PRESENTES NA INTERNET POR MEIO DE WEBSITE E/OU REDES SOCIAIS (2019)

Total de estabelecimentos de saúde que utilizaram a Internet nos últimos 12 meses (%)




As recomendações de isolamento social para prevenir a COVID-19 ocasionaram a necessidade de ampliação da oferta de serviços via Internet em diversas áreas, como comércio, educação, serviços bancários, serviços públicos e, também, serviços de saúde. A disponibilização de serviços de saúde via Internet, como agendamentos de consultas e exames, principalmente no caso da rede pública – em que grande parte dos usuários ainda precisa comparecer à UBS para realizar os agendamentos –, contribuiria para que essa parcela da população não precisasse se deslocar para efetuar essa etapa. Além disso, a automação poderia, também, aumentar a eficiência do serviço tanto para o estabelecimento quanto para o paciente.

Apesar da relevância da prestação de serviços via Internet e da centralidade da rede no cotidiano das pessoas, a pesquisa TIC Saúde aponta que, em um momento imediatamente anterior à pandemia, a oferta de serviços – como agendamento de consultas e exames, e a visualização de resultados de exames, entre outros – ainda era muito reduzida no país. A oferta desses serviços ainda difere entre os tipos e a esfera administrativa dos estabelecimentos. Os serviços de agendamento *on-line* foram oferecidos por cerca de um quarto dos estabelecimentos de saúde, em 2019, tendo permanecido estável ao longo da série histórica da pesquisa. Devido ao tipo de serviço que prestam, os SADT foram os que mais ofereceram agendamento de exames (39%) e visualização de resultados de exames (60%) via Internet. A visualização de seu prontuário eletrônico e a interação com a equipe médica foram os serviços menos oferecidos *on-line*, em todos os tipos de estabelecimentos de saúde.

GRÁFICO 8

ESTABELECIMENTOS DE SAÚDE, POR SERVIÇOS OFERECIDOS AO PACIENTE VIA INTERNET (2019)

Total de estabelecimentos de saúde que utilizaram a Internet nos últimos 12 meses (%)



Estabelecimentos públicos e privados mantiveram estáveis as proporções de oferta de serviços *on-line*, sendo que nos públicos foi mais baixa a frequência dos que ofereceram todos os tipos de serviços analisados pela pesquisa: agendamento de consultas (21% nos públicos e 27% nos privados), agendamento de exames (17%, em comparação a 28% nos privados) e serviço de visualização de resultados de exames (20% nos públicos contra 33% nos privados).

Algumas iniciativas vêm sendo desenvolvidas para ampliar a oferta desses serviços via Internet, principalmente no nível municipal. O aplicativo Agenda Fácil, desenvolvido pela prefeitura de São Paulo, é um exemplo e permite agendar, confirmar e cancelar consultas e exames nas UBS do município. Segundo dados da pesquisa TIC Governo Eletrônico 2019 (CGI.br, 2020e), 25% das prefeituras ofereceram a possibilidade de agendamento *on-line* de consultas, atendimentos e serviços por meio de *websites* em 2019. Outra iniciativa é o aplicativo Conecte SUS, do Ministério da Saúde, criado para viabilizar a interação com o cidadão (Portaria MS n. 1.434/2020). Essa iniciativa faz parte da Estratégia de Saúde Digital e prevê o acesso a consultas, exames, medicamentos prescritos, dados e orientações sobre doação de sangue, além de um cartão de vacinação que pretende auxiliar no controle de informações sobre dose, lote e validade.

SERVIÇOS DE TELESSAÚDE

A telemedicina é uma ferramenta eficaz para promover o distanciamento social em ambientes clínicos, necessário durante a pandemia. Sistemas de saúde de todo o mundo têm enfrentado o dilema de manter sua capacidade de oferta de serviços para os pacientes da COVID-19 e para os de outras doenças agudas ou crônicas, ao mesmo tempo em que protegem a saúde de seus profissionais (Bashshur, Doarn, Frenk, Kvedar, & Woolliscroft, 2020).

Diversos estudos demonstram as experiências da implementação da telemedicina em outros países. Entre eles, destacamos o desenvolvido por Ohannessian, Duong e Odone (2020). Eles relatam como a telemedicina, principalmente as videoconferências, tem sido adotada para reduzir o risco de transmissão nos Estados Unidos e no Reino Unido. O estudo também aponta que a maioria dos países têm dificuldades para implementar uma estrutura regulatória de telemedicina que autorize, integre e reembolse esses serviços. A Itália, por exemplo, não incluiu a telemedicina nos níveis essenciais do atendimento aos pacientes do Serviço Nacional de Saúde, enquanto a França já conta com uma estrutura avançada e de promoção do uso da telemedicina.


Mann, Chen, Chunara, Testa e Nov (2020), por sua vez, apresentaram um estudo de caso sobre o uso da telemedicina no NYU Langone Health durante o epicentro do surto da COVID-19 nos Estados Unidos. Os autores apontam que, após a expansão da equipe virtual, os atendimentos de urgência e não urgência via telemedicina aumentaram mais de 600%, entre março e maio de 2020, sendo que 56% dos atendimentos de urgência estavam relacionados à COVID-19. O estudo conclui que a rápida expansão e adaptação à telemedicina resultou em maior eficiência dos atendimentos e em prevenção da proliferação da doença, além de recomendar que outros sistemas de saúde se antecipem e regulamentem a telemedicina.

Bashshur *et al.* (2020) destacam que o rápido avanço da telemedicina neste período contrasta com sua lenta adoção pelos países, apesar de diversos estudos sobre sua relevância e diversas experiências positivas de implementação. No Brasil, a regulamentação da telessaúde foi amplamente discutida nos últimos anos, em função dos seus possíveis impactos no acesso à atenção à saúde pela população, principalmente para aqueles que não residem próximos aos centros urbanos. Seu uso pode trazer diversos benefícios, como a redução do tempo de atendimento, da fila de espera por consulta, de custos de deslocamento dos pacientes e dos profissionais e mais qualidade da assistência (Caetano *et al.*, 2020; Caffery, Farjian, & Smith, 2016).

No contexto da pandemia COVID-19, a telessaúde também possibilita pré-atendimentos para triagem, tratamentos menos complexos de outros tipos de doenças, diminuição da circulação de pessoas em estabelecimentos de saúde e em ambientes contaminantes. Essas ações contribuem para a redução do risco de contaminação e proliferação da doença, além de liberar leitos e vagas de atendimento hospitalar para pacientes infectados (Caetano *et al.*, 2020). O incentivo ao desenvolvimento da telessaúde pode ser importante para garantir a formação continuada de profissionais de saúde, em especial aqueles que não têm acesso aos principais polos de ensino brasileiros. Entre os programas nessa área, destaca-se o Programa Nacional Telessaúde Brasil Redes, que disponibiliza a educação permanente – além de teleconsultoria, telediagnóstico e segunda opinião formativa – aos profissionais da saúde. O intuito é proporcionar uma capacitação fundamentada nos desafios relacionados ao trabalho na área, melhorando assim a qualidade do atendimento prestado (Silva, 2017).

Dentro dos limites da Portaria MS n. 2.546, de 27 de outubro de 2011, vigente no momento da coleta dos dados da pesquisa, foram investigadas a adoção e a disponibilidade dos serviços de telessaúde pelos estabelecimentos brasileiros. Diante disso, verificou-se que os estabelecimentos públicos têm maior disponibilidade dos serviços de telessaúde do que os privados. O principal serviço oferecido foi a educação a distância em saúde, presente em 33% dos estabelecimentos públicos contra 8% dos privados, seguido por serviços de teleconsultoria (28% contra 3%) e atividades de pesquisa a distância (25% contra 5%). Vale destacar também que os estabelecimentos localizados nas regiões Norte e Nordeste disponibilizaram mais recursos para pesquisa a distância (20% em ambas) do que o que observado nas regiões Sudeste (10%), Sul (14%) e Centro-Oeste (13%). Nos demais itens investigados, verificou-se que as regiões Nordeste e Centro-Oeste foram as que tiveram esses recursos mais disponíveis, conforme o Gráfico 9.

GRÁFICO 9

ESTABELECIMENTOS DE SAÚDE, POR SERVIÇOS DE TELESSAÚDE DISPONÍVEIS (2019)*Total de estabelecimentos de saúde que utilizaram a Internet nos últimos 12 meses (%)*

A participação em redes de telessaúde também foi maior entre os estabelecimentos públicos, sendo praticamente nula entre os privados. Entre os públicos, 32% dos gestores declararam que o estabelecimento participa de redes estaduais de telessaúde, 19% citaram que fazem parte do Programa Nacional Telessaúde Brasil Redes e 11%, da Rede Universitária de Telemedicina (Rute). Contudo, 47% dos estabelecimentos públicos não estão ligados a nenhuma rede de telessaúde. Entre as regiões geográficas, destaca-se que cerca de um quinto (19%) dos estabelecimentos de saúde do Sul e do Centro-Oeste participam de redes estaduais, e que 13% dos estabelecimentos do Norte e 15% daqueles do Nordeste participam do Programa Nacional Telessaúde Brasil Redes.

Adoção das TIC nas Unidades Básicas de Saúde

As Unidades Básicas de Saúde (UBS) desempenham papel fundamental na vigilância local de saúde da população, por meio de prevenção e notificação de doenças. Segundo o Ministério da Saúde⁹, é na atenção primária que o paciente pode ter um acompanhamento mais próximo pelas equipes de profissionais da saúde, sendo possível resolver a maioria dos problemas de saúde da população.

Diante de surtos epidemiológicos e pandemias, a atenção primária ganha protagonismo, visto que entre suas principais funções estão o conhecimento do

⁹ Mais informações no *website* do Ministério da Saúde. Recuperado em 15 agosto, 2020, de <https://www.saude.gov.br/noticias/agencia-saude/46492-mais-de-3-mil-municipios-fazem-parte-do-programa-de-informatizacao-do-sus>

território, o vínculo entre paciente e equipe de saúde, o monitoramento das famílias em situação de vulnerabilidade e o acompanhamento de casos suspeitos ou leves. Além disso, estudos apontam que, em diversos países, cerca de 80% dos pacientes com casos leves e grande parte dos casos moderados de COVID-19 procuram os estabelecimentos da atenção primária para o atendimento inicial e a busca de cuidados (Sarti, Lazarini, Fontenelle, & Almeida, 2020; Dunlop, Howe, Li, & Allen, 2020).

A informatização das UBS pode proporcionar mais eficiência e agilidade no monitoramento, por meio do teleatendimento, da população em grupo de risco ou de pacientes que estejam com sintomas leves e que devem permanecer em isolamento social. O teleatendimento também facilita o encaminhamento dos casos mais graves para a atenção especializada e os Centros de Referência (MS, 2020b). Assim, é cada vez mais evidente a importância das UBS de todo o país estarem conectadas e informatizadas.


Diante da relevância da informatização das UBS para melhor funcionamento e organização de todo o sistema de saúde, a pesquisa TIC Saúde sinaliza um dos desafios dos gestores públicos, pois as UBS foram os tipos de estabelecimentos de saúde com menor disponibilidade de computadores e acesso à Internet. Em 2019, 91% delas tinham computador disponível e 82% tinham acesso à Internet, resultados que permaneceram estáveis em relação a 2018 (90% com computador e 80% com acesso à Internet). Em um universo de 40.880 UBS consideradas na pesquisa, estima-se que cerca de 3,6 mil ainda não tinham computador e cerca de 7,2 mil não estavam conectadas à rede.

Entre as UBS com computadores, o percentual das que possuem *tablets* aumentou nos últimos anos. Em 2019, 26% delas tinham *tablets*, enquanto em 2018 e 2017 esse percentual foi 18% e 9%, respectivamente. Os demais tipos de equipamentos, como computador de mesa (98%) e *notebook* (29%) não apresentaram alterações significativas no período.

Quanto aos tipos de conexões utilizadas, 96% das UBS tinham acesso à banda larga fixa¹⁰, sendo que a maioria (79%) contava com conexão via cabo ou fibra ótica, proporção que vem apresentando tendência de crescimento em relação aos anos anteriores (Gráfico 10). Verificou-se uma pequena diminuição da quantidade de UBS com conexões via rádio e satélite. Já o percentual de UBS com conexões móveis permaneceu estável.

¹⁰ O conceito de banda larga fixa corresponde às conexões via cabo ou fibra ótica, conexão via linha telefônica (DSL), conexão via rádio e via satélite.

GRÁFICO 10

UNIDADES BÁSICAS DE SAÚDE, POR TIPO DE CONEXÃO (2017 - 2019)*Total de estabelecimentos de saúde que utilizaram Internet nos últimos 12 meses (%)*

Novas políticas que visam aumentar a conectividade das UBS estão sendo implementadas, como o programa Conecte SUS, que lançou um projeto piloto para informatizar as UBS e dar cursos de capacitação em TIC e análise de dados para os agentes públicos das secretarias municipais de saúde. Além disso, o Ministério da Ciência, Tecnologia e Inovações (MCTI), em parceria com o Ministério da Saúde, está atuando para ampliar a conexão das UBS com equipes de saúde da família (ESF). Dentro desse programa, a Rede Nacional de Ensino e Pesquisa (RNP) está responsável pela gestão de editais e contratações de provedores locais para conectar cerca de 16 mil UBS. A prioridade é a contratação de conexão via fibra ótica e, em caso de indisponibilidade, será considerada a alternativa de conexões via rádio e via satélite (Rede Nacional de Ensino e Pesquisa [RNP], 2020).

Para além do tipo de conexão, outro dado importante para mapear a infraestrutura TIC das UBS é a faixa de velocidade para *download* da conexão à Internet. Em 2019, verificou-se aumento da contratação de faixas de velocidade mais altas para *download* da conexão principal e diminuição das faixas mais baixas. As UBS com conexões de até 1 Mbps passaram de 11%, em 2018, para 8%, em 2019. Já as com conexões acima de 10 Mbps passaram a ser 17%, aumento de cinco pontos percentuais sobre 2018. Um dado que chama a atenção foi a tendência de aumento do percentual de gestores que não souberam responder qual a faixa de velocidade da conexão contratada para o estabelecimento. Esse resultado pode ser explicado pelo fato de que, em geral, os serviços de infraestrutura de TIC nas UBS são contratados pelas secretarias de saúde, sem passar pela gestão local do estabelecimento.

As secretarias de saúde também exercem papel relevante na gestão e na governança de TIC nas UBS. Em 2019, apenas 10% das UBS contavam com a presença de uma


área, departamento ou setor de tecnologia da informação ou informática. Nas demais, o suporte técnico em informática era, majoritariamente, realizado por um prestador contratado pela secretaria de saúde (71% das UBS). Em 10% das UBS, esse serviço foi realizado por uma equipe interna, em 6% por prestador contratado por outra instituição e em 1% por prestador contratado pela própria UBS.

Frente ao recente debate acerca do tema de segurança da informação, mencionado anteriormente, os resultados da pesquisa demonstraram que as ferramentas de segurança estavam pouco presentes nas UBS, conforme o Gráfico 11. Entre os itens investigados, destacam-se as ferramentas como antivírus (81%) e proteção por senha do sistema (72%), que seguiam sendo as mais utilizadas. Ferramentas como criptografia de arquivos e *e-mails*, criptografia da base de dados, uso de assinatura eletrônica e uso de biometria para acesso ao sistema eletrônico apresentaram uma variação positiva em relação a 2018.

GRÁFICO 11

UNIDADES BÁSICAS DE SAÚDE, POR TIPO DE FERRAMENTA DE SEGURANÇA DA INFORMAÇÃO UTILIZADA (2017 - 2019)

Total de estabelecimentos de saúde que utilizaram Internet nos últimos 12 meses (%)



Ainda a respeito da proteção de dados, 15% dos gestores de UBS declararam que o estabelecimento possuía algum documento que definia uma política de segurança da informação, proporção que se mantém estável ao longo da série histórica.


Quando questionados sobre sua avaliação acerca da infraestrutura e da gestão e governança de TI, 40% dos gestores das UBS concordaram que os equipamentos de TI eram novos e atualizados, 32% afirmaram que a conexão de Internet era adequada às necessidades do estabelecimento e 36% que a UBS possuía um suporte de TI adequado. Esses dados apontam limites da infraestrutura e gestão de TIC nas UBS, o que é fundamental para a integração do sistema de saúde. Tais estabelecimentos são a base para que estratégias de informatização na área da saúde pública, como o e-SUS Atenção Primária¹¹ e outras iniciativas semelhantes, tenham sucesso, oferecendo mais acesso e melhores serviços aos cidadãos.

Em 2019, verificou-se uma melhora da situação das UBS em relação ao registro eletrônico de informações dos pacientes, dado que 78% delas possuíam um sistema eletrônico para esse fim, um aumento de nove pontos percentuais em relação a 2018. Essa variação positiva na adoção do Registro Eletrônico em Saúde (RES) impactou na maneira como são armazenadas as informações clínicas e cadastrais nos prontuários dos pacientes atendidos. Verificou-se uma diminuição do percentual de UBS que armazenavam as informações dos pacientes somente em papel. Conforme apontado no Gráfico 12, em 2018, esse grupo representava mais de um terço das UBS (35%) e, em 2019, passou para um quarto delas. Por outro lado, o percentual de UBS que mantinham as informações parte em papel e parte em formato eletrônico passou de 53%, em 2018, para 59%, em 2019.

GRÁFICO 12

UNIDADES BÁSICAS DE SAÚDE, POR FORMA DE MANUTENÇÃO DAS INFORMAÇÕES CLÍNICAS E CADASTRAIS NOS PRONTUÁRIOS DOS PACIENTES (2017 - 2019)

Total de estabelecimentos de saúde que utilizaram Internet nos últimos 12 meses (%)



¹¹ O e-SUS Atenção Primária (e-SUS APS) é uma estratégia do Departamento de Saúde da Família para reestruturar as informações da atenção primária à saúde (APS) em nível nacional. Este programa faz parte da proposta de reestruturação dos Sistemas de Informação em Saúde desenvolvido pelo Ministério da Saúde. Mais informações no *website* do Ministério da Saúde. Recuperado em 15 agosto, 2020, de <https://aps.saude.gov.br/ape/esus>

O resultado aponta para um momento de transição no processo de informatização dos dados. No entanto, apesar da tendência de redução da quantidade de UBS que utilizavam apenas papel no registro de dados, não houve um crescimento significativo de estabelecimentos adotando apenas o formato eletrônico para manutenção das informações clínicas e cadastrais nos prontuários dos pacientes. Entre as UBS que mantiveram as informações em formato eletrônico, 39% tinham a prática de imprimi-lo, proporção que se manteve praticamente estável em relação a 2018 (35%). A necessidade de impressão dos prontuários pode ser justificada por eventuais procedimentos internos de controle dos atendimentos que ocorrem no estabelecimento.

Esses dados podem apontar dificuldade em consultar informações eletrônicas em salas de atendimento que não possuam computadores ou em estabelecimentos cuja demanda seja superior à disponibilidade de equipamentos. Em 55% das UBS, os profissionais podiam acessar informações do paciente de qualquer local da UBS a partir de uma rede interna, por meio de computador portátil, *tablet* ou celular, e em somente 34% esses dados podiam ser acessados de fora do estabelecimento, pela Internet.


A disponibilidade para consulta em formato eletrônico de diferentes tipos de informações dos pacientes apresentou tendência de crescimento nos últimos anos. Desde 2017, todas as informações investigadas pela pesquisa apresentaram variação positiva. O Gráfico 13 mostra que, em 2019, as informações mais disponíveis eletronicamente foram os dados cadastrais (87%) e as vacinas administradas ao paciente (80%).

As informações que apresentaram os maiores aumentos percentuais em relação a 2018 foram: os principais motivos que levaram o paciente ao atendimento ou consulta (antes podiam ser visualizados eletronicamente em 60% dos estabelecimentos e passaram a estar disponíveis em 78% deles, em 2019); os diagnósticos, problemas ou condições de saúde do paciente (passaram de 61% para 76%); as alergias (de 54% para 69%); e os dados de admissão, transferência e alta (de 45% para 59%).

GRÁFICO 13


UNIDADES BÁSICAS DE SAÚDE, POR TIPO DE DADO SOBRE O PACIENTE DISPONÍVEL ELETRONICAMENTE (2017 - 2019)

Total de estabelecimentos de saúde que utilizaram Internet nos últimos 12 meses (%)



O Gráfico 14 apresenta as funcionalidades mais disponíveis nas UBS, conforme seu tipo de classificação. Verifica-se que aquelas relacionadas a atividades administrativas são as presentes em mais estabelecimentos, e com tendência de crescimento nos últimos anos. Funcionalidades que dão suporte às decisões dos profissionais de saúde são menos encontradas nos sistemas das UBS, estando presentes em cerca de um quarto delas. As que proporcionam troca de informações com outros estabelecimentos também aparecem em poucas UBS, e não apresentaram aumento significativo nos últimos anos.

GRÁFICO 14

UNIDADES BÁSICAS DE SAÚDE, POR FUNCIONALIDADES ELETRÔNICAS DISPONÍVEIS EM SISTEMA (2017 - 2019)*Total de estabelecimentos de saúde que utilizaram Internet nos últimos 12 meses (%)*

A presença das UBS na Internet pode contribuir para a difusão de campanhas de vacinação e de prevenção de doenças, além de facilitar o acesso a informações sobre horários de atendimento – aspecto fundamental para estratégias de imunização relacionadas à COVID-19. No entanto, apenas 21% delas tinham *website* e 20% possuíam perfil ou conta própria em alguma rede social. Com relação à disponibilização de serviços *on-line* para os pacientes, não houve alterações significativas no período. Em 2019, 23% disponibilizaram agendamento de consultas, 22% permitiram a visualização de resultados de exames e 20%, o agendamento de exames *on-line*. A possibilidade de visualização do prontuário do paciente (12%) e de interação com a equipe médica (7%) por meio da Internet foram ainda menos frequentes.

Já os serviços de telessaúde estavam mais presentes nas UBS. Em 2019, 39% delas ofereceram o serviço de educação a distância em saúde. Aproximadamente um terço disponibilizou teleconsultoria (35%) e atividades de pesquisa a distância (30%). Em 25% delas havia à disposição o serviço de telediagnóstico, em 20% o serviço de segunda opinião formativa e em 8% era possível o monitoramento remoto de pacientes.

Sobre a participação das UBS em redes de telessaúde, em 2019, 57% dos gestores declararam que a unidade participava de alguma rede, o que representa uma variação

positiva em relação ao observado em 2018 (48%). Entre as redes investigadas, 40% das UBS participavam das Redes Estaduais de Telessaúde, 23% faziam parte do Programa Nacional Telessaúde Brasil Redes, 14% colaboravam com a Rute da RNP e 11% participavam de outras redes de telessaúde.

Acesso e uso das TIC pelos profissionais de saúde

O uso e a apropriação das TIC pelos profissionais de saúde é um aspecto fundamental para o sucesso do processo de informatização dos estabelecimentos de saúde. A devida capacitação desses profissionais é um aspecto relevante para o avanço da saúde digital, bem como seu engajamento na adoção de novos dispositivos e sistemas em sua rotina de atendimento e cuidado da saúde dos pacientes.

A disponibilidade de computadores para uso de médicos e enfermeiros permaneceu relativamente estável nos últimos anos. Em 2019, 88% dos médicos tinham acesso a computador no estabelecimento de saúde e 94%, acesso à Internet. Além disso, entre os médicos que atuam em estabelecimentos públicos, 23% declararam não ter computador disponível, percentual elevado em comparação àqueles que atuam em estabelecimentos privados (3%). Já entre os enfermeiros, 90% dispunham de computadores e 92% tinham acesso à Internet. A diferença de disponibilidade de computadores entre os enfermeiros de estabelecimentos privados e públicos é um pouco menor em relação à dos médicos, visto que 86% dos enfermeiros de estabelecimentos públicos e 98% dos que trabalham em estabelecimentos privados informaram ter computadores disponíveis.

O uso do computador no atendimento aos pacientes influencia a maneira como é realizada a prescrição médica. A maior parte dos médicos com computador disponível realizava as prescrições em formato eletrônico (54%) e 31% deles o faziam tanto em formato eletrônico quanto manualmente, proporções estáveis em relação aos anos anteriores. Em 2019, 14% dos médicos declararam fazer suas prescrições apenas manualmente, proporção estável em relação a 2018. Ressalta-se que, nos estabelecimentos com internação e mais de 50 leitos, 75% dos médicos realizavam a prescrição em formato eletrônico.

Apesar do uso do computador no momento de fazer as prescrições, a maior parte dos médicos continua assinando-as manualmente (71%), o que aponta para um grande espaço para a expansão do uso do certificado digital, adotado por apenas 12% deles. Mesmo nos estabelecimentos com internação e mais de 50 leitos, a maioria (74%) assina manualmente a prescrição médica. Com a nova regulamentação das teleconsultas por conta da pandemia COVID-19 e da necessidade de distanciamento social, a regulamentação e o uso da prescrição eletrônica avançaram no país.¹²

Em relação à percepção dos profissionais sobre a infraestrutura e a gestão das TIC nos estabelecimentos em que trabalham, cerca de metade dos médicos e enfermeiros concordaram que a conexão de Internet é adequada às suas necessidades (53% para ambos) e que o estabelecimento possui um suporte técnico de TI adequado (52%

¹² Ver mais informações na Portaria MS n. 467/2020.

para ambos). Quanto aos equipamentos de TI disponíveis no estabelecimento onde trabalham, 45% dos médicos e 46% dos enfermeiros concordaram que estes eram novos e atualizados. No geral, a infraestrutura TIC foi melhor avaliada pelos profissionais que atuam nos estabelecimentos privados.

SISTEMAS ELETRÔNICOS E USO DE FUNCIONALIDADES PELOS PROFISSIONAIS DE SAÚDE

A disponibilidade do registro eletrônico das informações de saúde do paciente é essencial para garantir melhores atendimentos e diagnósticos, além de otimizar a tomada de decisão dos profissionais da saúde, visto que possibilita o acesso e o acompanhamento de mais dados de forma sistematizada e em menos tempo.

Entre os dados em formato eletrônico que tanto médicos quanto enfermeiros informaram acessar sempre, foram: os principais motivos que levaram os pacientes ao atendimento; os diagnósticos, problemas ou condições de saúde do paciente; e o histórico ou as anotações clínicas sobre o atendimento, conforme os Gráficos 15 e 16. Ressalta-se que a frequência de consulta aos dados se manteve estável em relação a 2018, com exceção da consulta aos dados cadastrais dos pacientes, que apresentou aumento considerável tanto entre médicos (de 33%, em 2018, para 63%, em 2019) quanto entre enfermeiros (de 41%, em 2018, para 59%, em 2019).

GRÁFICO 15

MÉDICOS, POR FREQUÊNCIA DE CONSULTAS AOS DADOS SOBRE OS PACIENTES DISPONÍVEIS ELETRONICAMENTE (2019)

Total de médicos com acesso a computador no estabelecimento de saúde (%)





GRÁFICO 16

ENFERMEIROS, POR FREQUÊNCIA DE CONSULTAS AOS DADOS SOBRE OS PACIENTES DISPONÍVEIS ELETRONICAMENTE (2019)

Total de enfermeiros com acesso a computador no estabelecimento de saúde (%)



A presença de recursos de segurança para o acesso às informações clínicas e cadastrais dos pacientes é de suma importância para garantir a proteção das informações armazenadas. Nesse sentido, a senha de acesso continuou sendo a mais utilizada tanto por médicos (94%) quanto por enfermeiros (91%). Um quarto dos médicos (26%) e enfermeiros (25%) declararam fazer uso de certificado digital, enquanto menos de um décimo dos médicos (8%) e dos enfermeiros (5%) informaram utilizar biometria para acessar os dados dos pacientes.

As diferenças na natureza das atividades e funções exercidas por médicos e enfermeiros ficam evidentes quando são observadas a frequência de uso das funcionalidades dos sistemas eletrônicos. Conforme os Gráficos 17 e 18, cerca de metade dos médicos utilizavam sempre a funcionalidade de pedir exames laboratoriais e quatro em cada dez sempre se valiam das funcionalidades de pedir exames de imagem e de listar todos os medicamentos que um paciente usa. Os enfermeiros, por sua vez, recorriam mais às funcionalidades de listar todos os medicamentos que um paciente usa, de gerar pedidos de materiais e suprimentos e de listar todos os resultados de exames laboratoriais de um paciente específico.

GRÁFICO 17



MÉDICOS, POR FREQUÊNCIA DE USO DAS FUNCIONALIDADES ELETRÔNICAS DISPONÍVEIS EM SISTEMA (2019)*Total de médicos com acesso a computador no estabelecimento de saúde (%)*

GRÁFICO 18

ENFERMEIROS, POR FREQUÊNCIA DE USO DAS FUNCIONALIDADES ELETRÔNICAS DISPONÍVEIS EM SISTEMA (2019)*Total de enfermeiros com acesso a computador no estabelecimento de saúde (%)***ADOÇÃO DE ESTRATÉGIAS DE TELESSAÚDE PELOS PROFISSIONAIS**

Com a possibilidade de transpor barreiras geográficas e facilitar a alocação dos profissionais de saúde, a implantação da telessaúde pode ampliar de forma significativa o acesso dos cidadãos ao atendimento com mais qualidade, equidade e eficiência. A pesquisa TIC Saúde 2019 aponta que o principal serviço de telessaúde disponível

nos estabelecimentos era a educação a distância em saúde, resultado importante no tocante à formação continuada dos profissionais do setor.

Os demais recursos permanecem pouco disponibilizados nos estabelecimentos em que os profissionais atuam. As atividades de pesquisa a distância, teleconsultoria, segunda opinião formativa e telediagnóstico foram utilizadas por cerca de um quarto dos profissionais de saúde. Já o monitoramento remoto de pacientes estava disponível para apenas 9% dos médicos e 16% dos enfermeiros.

Em relação a 2018, a disponibilidade de educação a distância em saúde, no caso dos médicos, aumentou na região Sudeste (de 20% para 52%) e nos estabelecimentos localizados no interior (de 21% para 43%). Já as atividades de pesquisa a distância apresentaram diminuição, no mesmo período, entre os enfermeiros (de 43% para 28%). Para os enfermeiros, a educação a distância em saúde foi, ao longo de toda a série histórica da pesquisa, o recurso de telessaúde mais disponível nos estabelecimentos em que atuavam. Em 2019, 44% dos enfermeiros contavam com esse recurso, chegando a 61% entre aqueles que trabalhavam em UBS.

APROPRIAÇÃO DAS TIC POR MÉDICOS E ENFERMEIROS

Para que o desenvolvimento e a adoção de novas tecnologias na área da saúde sejam eficientes – não apenas na gestão das informações e dos estabelecimentos de saúde, mas no atendimento e acesso aos usuários do sistema de saúde –, é importante que os profissionais recebam qualificação adequada na área de tecnologia da informação e comunicação.

No entanto, uma parcela reduzida dos profissionais da área da saúde frequentou cursos na área de TIC. Em 2019, o treinamento ou capacitação em informática em saúde foi o tipo de curso com maior adesão entre enfermeiros (36%) e médicos (30%), principalmente entre médicos que atuavam em estabelecimentos privados (40%). Por outro lado, a participação em cursos de especialização (6% dos médicos e 8% dos enfermeiros), mestrado (1% dos médicos e 1% dos enfermeiros) e doutorado (1% dos médicos) na área de informática em saúde foi menos frequente.

A apropriação das TIC no trabalho de médicos e enfermeiros também pode ser observada por meio de suas percepções sobre os impactos que elas exercem em suas atividades. Em 2019, a maior parte dos enfermeiros (60%) não identificou impactos do uso de computador e Internet no seu volume de trabalho, nem para mais, nem para menos. Os enfermeiros que perceberam algum impacto se dividem de forma equivalente entre aqueles que acreditam que a carga de trabalho aumentou (22%) e aqueles que afirmam que ela diminuiu (17%). Apesar disso, vale destacar que foi mais frequente entre os enfermeiros que trabalham em estabelecimentos públicos (25%) e em UBS (37%) a percepção de que o uso do computador aumentou sua carga de trabalho, se comparados àqueles que trabalham em estabelecimentos privados (16%).

Entre os médicos, apesar da maior parte considerar que não houve mudança na carga de trabalho (43%), a percepção de que o computador e a Internet diminuiram o seu volume de trabalho foi mais frequente entre eles do que entre os enfermeiros: em 2019, 33% dos médicos consideraram que houve redução na sua carga de trabalho.

A avaliação que os médicos fazem sobre a influência do computador e da Internet na diminuição do volume de trabalho pode ser reflexo do aumento na frequência com que esses profissionais utilizam o computador para o atendimento aos pacientes.

Em geral, os profissionais de saúde avaliaram de forma positiva os impactos do uso dos sistemas eletrônicos, conforme Gráficos 19 e 20. Os principais benefícios das TIC, segundo os médicos, foram a melhoria na eficiência dos processos de trabalho das equipes (88%), a redução de erros na administração de medicamentos (83%), a melhoria na qualidade do tratamento como um todo (83%) e a maior eficiência nos atendimentos (81%). Entre os enfermeiros, a avaliação do impacto da implantação ou uso de sistemas eletrônicos foi relativamente melhor: nove em cada dez profissionais concordaram que houve melhoria na eficiência dos processos de trabalho das equipes (94%), maior eficiência nos atendimentos (91%) e melhora na qualidade do tratamento como um todo (88%). Os enfermeiros também concordaram amplamente com relação à melhoria na qualidade das decisões sobre os diagnósticos (86%) e à diminuição de exames duplicados ou desnecessários (84%).

GRÁFICO 19

MÉDICOS, POR IMPACTOS PERCEBIDOS EM RELAÇÃO AO USO OU IMPLANTAÇÃO DE SISTEMAS ELETRÔNICOS (2019)

Total de médicos (%)





GRÁFICO 20

ENFERMEIROS, POR IMPACTOS PERCEBIDOS EM RELAÇÃO AO USO OU IMPLANTAÇÃO DE SISTEMAS ELETRÔNICOS (2019)

Total de enfermeiros (%)



Considerações finais: agenda para políticas públicas

A infraestrutura de tecnologia de informação e comunicação nos estabelecimentos de saúde avançou nos últimos anos, conforme apontam os resultados da pesquisa TIC Saúde 2019. No entanto, embora universalizada na rede privada, ainda não alcançou o mesmo patamar nos estabelecimentos da rede pública. Também permanecem as disparidades entre as regiões geográficas do país, sendo as regiões Norte e Nordeste as mais afetadas. É estratégico propiciar infraestrutura aos locais mais distantes dos grandes centros urbanos e implementar medições da qualidade destas conexões como premissa de uma política de incentivo de usos mais complexos das TIC na saúde.

A situação ímpar de pandemia, pela qual o mundo passa desde o início de 2020, evidenciou ainda mais as desigualdades de acesso às tecnologias, mas também fez emergir a urgência da implantação da saúde digital e da necessidade de informatização dos serviços públicos. A particularidade desse momento exigiu o desenvolvimento de ações inovadoras no sistema de saúde, como a criação de novos aplicativos que auxiliassem a autoavaliação dos cidadãos e a integração entre os diversos níveis da atenção à saúde. Além disso, tornam-se urgentes a disponibilização de um sistema de informações integrado e coordenado com estados, municípios e demais órgãos relacionados à área da saúde, o monitoramento dos cidadãos em grupo de risco e em áreas mais vulneráveis, a busca ativa de possíveis infectados, além da divulgação de informações sobre a nova doença e a situação da pandemia no país.

Nesse sentido, é fundamental monitorar a implementação de estratégias de conectividade, tais como o programa Conecte SUS, desenvolvido pelo Datasus e composto pela Rede Nacional de Dados em Saúde e pela Informatização da Atenção à Saúde. Com isto, será possível potencializar a troca de informações entre os sistemas de prontuários eletrônicos, e elaborar estratégias que auxiliem na autoavaliação sobre os sintomas da COVID-19, assim como divulgar alertas de infecção pela doença. No plano local, diversas prefeituras em todo o país vêm desenvolvendo aplicativos que permitem o atendimento e monitoramento a distância dos pacientes da rede pública.

Outro passo importante está na regulamentação da telessaúde no país, realizada em caráter emergencial pelo Ministério da Saúde, autorizando que médicos usem ferramentas de telemedicina para a orientação, encaminhamento e monitoramento de indivíduos com suspeita ou com casos leves da COVID-19. Restrita ao período da pandemia, essa regulamentação fez com que o teleatendimento passasse a constar oficialmente do protocolo nacional de manejo clínico da COVID-19 no contexto da saúde no país, resultando na adoção de centrais de atendimento de telessaúde (Sarti *et al.*, 2020).

Os potenciais benefícios gerados pela expansão da utilização das ferramentas de telessaúde indicam a importância de rever a vigência desse protocolo de atendimento para além do período de pandemia no país, e de forma abrangente por todo o sistema de saúde. Para que isso se torne realidade, será necessário um investimento massivo com vistas à universalização das TIC em todos os estabelecimentos de saúde públicos, considerando os diferentes níveis de atenção.

Há também que se ponderar sobre os riscos em potencial que a rápida expansão do uso das tecnologias, em situações de emergências em saúde, pode trazer para a segurança e privacidade das informações dos pacientes. A vigilância digital por meio de rastreamentos por aplicativos de *smartphones* e o uso de geolocalização e de reconhecimento facial devem seguir regulações específicas e atentar à dimensão ética desse uso, para que os dados não sejam usados para diferentes fins que não a saúde pessoal ou pública. Os dados da pesquisa também indicam que políticas públicas podem incentivar a adoção de documentos, estratégias e ferramentas para proteger registros em saúde de pacientes, alvos potenciais de roubos de dados por se tratar de bases amplas de informação documental.

Diante disso, o avanço das TIC na área da saúde e a expansão da saúde digital devem ser encarados como uma política pública necessária e urgente, a ser aplicada para melhorar as condições de acesso e qualidade dos cuidados em saúde, a privacidade dos dados dos pacientes, e o acesso a informações de prevenção de doenças, favorecendo o bem-estar da população.

Referências

- Bashshur, R., Doarn, C. R., Frenk, J. M., Kvedar, J. C., & Woolliscroft, J. O. (2020, maio 6) *Telemedicine and the COVID-19 pandemic, lessons for the future*. Recuperado em 15 agosto, 2020, de <http://doi.org/10.1089/tmj.2020.29040.rb>
- Caetano, R., Silva, A. B., Guedes, A. C. C. M., Paiva, C. C. N., Ribeiro, G. R., Santos, D. L., & Silva, R. M. (2020). Desafios e oportunidades para telessaúde em tempos da pandemia pela COVID-19: Uma reflexão sobre os espaços e iniciativas no contexto brasileiro. *Cadernos de Saúde Pública*, 36(5), e00088920.
- Caffery, L. J., Farjian, M., & Smith, A. C. (2016). Telehealth interventions for reducing waiting lists and waiting times for specialist outpatient services: A scoping review. *Journal of Telemedicine and Telecare*, 22(8), 504–512.
- Comitê Gestor da Internet no Brasil – CGI.br. (2020a). *Pesquisa sobre o uso das tecnologias de informação e comunicação nas empresas brasileiras: TIC Empresas 2019*. São Paulo: CGI.br.
- Comitê Gestor da Internet no Brasil – CGI.br. (2020b). *Pesquisa sobre o uso das tecnologias de informação e comunicação nas escolas brasileiras: TIC Educação 2019*. São Paulo: CGI.br.
- Comitê Gestor da Internet no Brasil – CGI.br. (2020c). *Pesquisa sobre o uso das tecnologias de informação e comunicação nos domicílios brasileiros: TIC Domicílios 2019*. São Paulo: CGI.br.
- Comitê Gestor da Internet no Brasil – CGI.br. (2020d). *Painel TIC COVID-19: Pesquisa sobre o uso da Internet no Brasil durante a pandemia do novo coronavírus: Atividades na Internet, Cultura e Comércio Eletrônico* (1ª edição). São Paulo: CGI.br.
- Comitê Gestor da Internet no Brasil – CGI.br. (2020e). *Pesquisa sobre o uso das tecnologias de informação e comunicação no setor público brasileiro: TIC Governo Eletrônico 2019*. São Paulo: CGI.br.
- Dorsey, E. R., & Topol, E. J. (2020, março 14). Telemedicine 2020 and the next decade. *Lancet*, 395(10227), 859.
- Dunlop, C., Howe, A., Li, D., & Allen, L.N. (2020) The coronavirus outbreak: the central role of primary care in emergency preparedness and response. *BJGP Open*, 4(1).
- Greenhalgh, T., Wherton, J., Shaw, S., & Morrison, C. (2020). Video consultations for COVID-19. *BMJ*, 368(m998).
- Guañes, P. C. V. (Org.) (2018). *Marcos legais nacionais em face da abertura de dados para pesquisa em saúde: Dados pessoais, sensíveis ou sigilosos e propriedade intelectual*. Rio de Janeiro: Fiocruz.
- Holden, R. J., Binkheder, S., Patel, J., & Viernes, S.H.P. (2017). Best practices for health informatician involvement in interprofessional health care teams. *Applied Clinical Informatics*, 9(1), 141-148.
- Janett, R. S., & Yeracaris, P. P. (2020). Electronic Medical Records in the American Health System: challenges and lessons learned. *Ciência & Saúde pública*, 25(4), 1293-1304.
- Lei Geral de Proteção de Dados Pessoais – LGPD*. Lei n. 13.709, de 14 de agosto de 2018. (2018). Dispõe sobre o tratamento de dados pessoais, inclusive nos meios digitais, por pessoa natural ou por pessoa jurídica de direito público ou privado, com o objetivo de proteger os direitos fundamentais de liberdade e de privacidade e o livre desenvolvimento da personalidade da pessoa natural. Brasília, DF. Recuperado em 15 agosto, 2020, de http://www.planalto.gov.br/ccivil_03/_Ato2015-2018/2018/Lei/L13709.htm

Lei n. 13.989, de 15 de abril de 2020. (2020). Dispõe sobre o uso da telemedicina durante a crise causada pelo coronavírus (SARS-CoV-2). Brasília, DF. Recuperado em 15 agosto, 2020, de http://www.planalto.gov.br/ccivil_03/_ato2019-2022/2020/Lei/L13989.htm

Mann, D. M., Chen, J., Chunara, R., Testa, P. A., & Nov, O. (2020). COVID-19 transforms health care through telemedicine: Evidence from the field. *Journal of the American Medical Informatics Association*, 27(7), 1132–1135.

Ministério da Saúde – MS. (2020a). *Aplicativo Coronavírus-SUS vai alertar contatos próximos de pacientes com Covid-19*. Recuperado em 15 agosto, 2020, de <https://www.saude.gov.br/noticias/agencia-saude/47292-aplicativo-coronavirus-sus-vai-alertar-contatos-proximos-de-pacientes-com-covid-19>

Ministério da Saúde – MS. (2020b). *Protocolo de manejo clínico do coronavírus (COVID-19) na atenção primária à saúde*. Recuperado em 15 agosto, 2020, de <https://saude.rs.gov.br/upload/arquivos/202004/14140606-4-ms-protocolomanejo-aps-ver07abr.pdf>

Ministério da Saúde – MS. (2017). *Estratégia de Saúde Digital para Brasil*. Recuperado em 15 agosto, 2020, de https://saudedigital.saude.gov.br/wp-content/uploads/2020/02/Estrategia-e-saude-para-o-Brasil_CIT_20170604.pdf

Ohannessian, R., Duong, T.A., & Odone, A. (2020). Global telemedicine implementation and integration within health systems to fight the COVID-19 pandemic: A call to action. *JMIR Public Health Surveill*, 6(2), e18810.

Organização Mundial da Saúde – OMS. (2020). *Coronavirus disease 2019 (COVID-19): Situation report 51*. Recuperado em 15 agosto, 2020, de https://www.who.int/docs/default-source/coronaviruse/situation-reports/20200311-sitrep-51-covid-19.pdf?sfvrsn=1ba62e57_10

Organização Pan-Americana de Saúde – Opas. (2020a). *Fichas Informativas COVID-19: Registros eletrônicos de saúde e interoperabilidade – Dois conceitos fundamentais para melhorar a resposta em saúde pública*. Recuperado em 15 agosto, 2020, de <https://iris.paho.org/handle/10665.2/52005>

Organização Pan-Americana de Saúde – Opas. (2020b). *Fichas Informativas COVID-19: Por que a desagregação de dados é essencial durante pandemias*. Recuperado em 15 agosto, 2020, de <https://iris.paho.org/handle/10665.2/52072>

Pinheiro, P. P. (2018). *Proteção de dados pessoais: Comentários à Lei n. 13.709/2018 (LGPD)* [E-book]. São Paulo: Saraiva Educação.

Portaria MS n. 467, de 20 março de 2020. (2020). Dispõe, em caráter excepcional e temporário, sobre as ações de Telemedicina, com o objetivo de regulamentar e operacionalizar as medidas de enfrentamento da emergência de saúde pública de importância internacional previstas no art. 3º da Lei n. 13.979, de 6 de fevereiro de 2020, decorrente da epidemia de COVID-19. Brasília, DF. Recuperado em 15 agosto, 2020, de <http://www.in.gov.br/en/web/dou/-/portaria-n-467-de-20-de-marco-de-2020-249312996>

Portaria MS n. 1.434, de 28 de maio de 2020. (2020). Institui o Programa Conecte SUS e altera a Portaria de Consolidação n. 1/GM/MS, de 28 de setembro de 2017, para instituir a Rede Nacional de Dados em Saúde e dispor sobre a adoção de padrões de interoperabilidade em saúde. Brasília, DF. Recuperado em 15 agosto, 2020, de <https://rnds.saude.gov.br/wp-content/uploads/2020/06/portaria-n%C2%BA-1.434-202.pdf>

- Portaria MS n. 2.546, de 27 de outubro de 2011. (2011). Redefine e amplia o Programa Telessaúde Brasil, que passa a ser denominado Programa Nacional Telessaúde Brasil Redes (Telessaúde Brasil Redes). Brasília, DF. Recuperado em 15 agosto, 2020, de http://bvsms.saude.gov.br/bvs/saudelegis/gm/2011/prt2546_27_10_2011.html
- Portnoy, J., Waller, M., & Elliott, T. (2020). Telemedicina na era da COVID-19. *The Journal of Allergy Clinical Immunology: In Practice*, 8(5), 1489-1491.
- Rede Nacional de Ensino e Pesquisa – RNP. (2020). *Aberta a segunda chamada para a conexão de postos de saúde de todo o país*. Recuperado em 15 agosto, 2020, de <https://www.rnp.br/noticias/aberta-segunda-chamada-para-conexao-de-postos-de-saude-de-todo-o-pais>
- Santos, R. V., & Terra, R. (2020). A Governança de tecnologia da informação em hospitais melhorando os resultados estratégicos. *Journal of Health Informatics*, 10(2), 64-68.
- Sarlet, G. B. S., & Molinaro, C. A. (2019). Questões tecnológicas, éticas e normativas da proteção de dados pessoais na área da saúde em um contexto de Big Data. *Direitos Fundamentais & Justiça*, 13(41), 183-212.
- Sarti, T. D., Lazarini, W. S., Fontenelle, L. F., & Almeida, A. P. S. C. (2020). Qual o papel da Atenção Primária à Saúde diante da pandemia provocada pela COVID-19?. *Epidemiologia e Serviços de Saúde*, 29(2), e2020166.
- Silva, E. (2017). A telessaúde e seus impactos na formação continuada dos profissionais de saúde em rede. *Em Rede – Revista de educação a distância*, 4(1), 116-129.
- Siqueira, L.S., & Hoch, P.A. (2019). Os dados pessoais e a proteção de dados de saúde: análise a partir de iniciativas de e-Saúde. *Congresso Internacional de Direito e Contemporaneidade*, Rio Grande do Sul, RS, Brasil.
- Sousa, J. H. Jr., Raasch, M., Soares, J. C., & Ribeiro, L. V. H. A. S. (2020). Da desinformação ao caos: uma análise das fake news frente à pandemia do coronavírus (COVID-19) no Brasil. *Cadernos de Prospecção*, 13(2), 331-346.
- Spagnoli, J. A., & Soares, M. N. (2020). *O uso da Inteligência Artificial na nova pandemia SARS-COV-2 e a responsabilidade civil médica e os impactos na nova LGPD*. Recuperado em 15 agosto, 2020, de <https://blog.vendruscolospagnoli.com.br/o-uso-da-inteligencia-artificial-na-nova-pandemia-sars-cov-2-e-a-responsabilidade-civil-medica-e-os-impactos-na-nova-lgpd/>
- Stoeger, K., & Schmidhuber, M. (2020). The use of data from electronic health records in times of a pandemic: a legal and ethical assessment. *Journal of Law and the Biosciences*, 7(1).
- Sutton, R. T., Pincock, D., Baumgart, D. C., Sadowski, D. C., Fedorak, R. N., & Kroeker, K. I. (2020). An overview of clinical decision support systems: Benefits, risks, and strategies for success. *npj Digit. Med.*, 3, 17.
- Tunes, S. (2020, abril 14). Inteligência artificial contra a COVID-19. *Revista Pesquisa Fapesp*. Recuperado em 15 agosto, 2020, de <https://revistapesquisa.fapesp.br/inteligencia-artificial-contra-a-covid-19/>

ARTIGOS



Rede nacional de dados em saúde: experiência de interoperabilidade na rede de atenção à saúde

Jacson Venâncio de Barros¹, Henrique Nixon Souza da Silva², Roberta Massa Baptista³, Frank James da Silva Pires⁴ e Juliana Pereira de Souza-Zinader⁵

Introdução

Com o avanço tecnológico, a valorização da informação, o ritmo acelerado das mudanças e a globalização, uma nova era da informação foi aberta no âmbito da saúde e está agora em curso. Isso se deve, em parte, à adoção generalizada do Registro Eletrônico de Saúde (RES) nos últimos anos, e ao crescente interesse na análise e gestão desses registros (Raghupathi & Raghupathi, 2014). Considerando que, muitas vezes, pacientes recebem tratamento médico de diferentes profissionais e por diferentes instituições de saúde, a disponibilidade e o compartilhamento de informações são essenciais para o cuidado presente e contínuo desses indivíduos.

A Organização Mundial da Saúde (OMS), por exemplo, tem defendido que o acesso à informação em saúde centrada no paciente é uma demanda global e deve ser priorizada (Organização Mundial da Saúde [OMS], 2019). Outras iniciativas ampliam essas discussões

¹ Diretor do Departamento de Informática em Saúde do Sistema Único de Saúde, da Secretaria Executiva do Ministério da Saúde (Datasus/SE/MS), mestre em Ciência Médicas pela Faculdade de Medicina da Universidade de São Paulo (USP) e doutorando pelo Departamento de Informática Médica da Faculdade de Medicina da USP.

² Coordenador-geral de Sistemas de Informações e Operações do Datasus, bacharel em Rede de Computadores e especialista em Segurança da Informação pela Universidade de Brasília (UnB).

³ Coordenadora-geral de Governança e Gestão de Projetos em TIC do Datasus, bacharel em Administração Hospitalar pelo Centro Universitário São Camilo. Especialista em Gestão da Qualidade em Saúde pelo Instituto Israelita de Ensino e Pesquisa Hospital Albert Einstein e cursa MBA executivo em Gestão em Saúde pela Fundação Getúlio Vargas (FGV).

⁴ Coordenador-geral de Infraestrutura do Datasus, bacharel em Sistemas de Informação e analista em Tecnologia da Informação do Ministério da Economia. Cursando Especialização em Informática em Saúde pelo Instituto Sírio-Libanês de Ensino e Pesquisa.

⁵ Coordenadora-geral de Inovação em Sistemas Digitais do Datasus (servidora cedida) e professora adjunta no Instituto de Informática da Universidade Federal de Goiás (UFGO). Doutora em Ciências pelo Programa de Pós-Graduação Interunidades em Bioengenharia (Escola de Engenharia de São Carlos, Faculdade de Medicina de Ribeirão Preto e Instituto de Química de São Paulo, da USP).

intergovernamentais, como a Global Digital Health Partnership⁶ (GDHP), cujos estudos fortalecem a tese de que apenas com o uso de padrões comuns alcançaremos o alinhamento global e a interoperabilidade internacional (Global Digital Health Partnership [GDHP], 2019).

Com o estabelecimento da Resolução WHA71-7, aprovada em 2018 na 71ª Assembleia Mundial de Saúde da OMS – que atualiza os direcionadores e termos relativos à utilização da tecnologia da informação no contexto da saúde –, encontram-se em pauta a interconectividade das tecnologias digitais ou ciberinfraestrutura; a coleta, gestão e avaliação de dados e informações em saúde; a robustez do ambiente favorável, em consonância com as boas práticas estabelecidas, considerando a sustentabilidade e as inovações; e a atual viabilidade, escalabilidade e inclusividade com as tecnologias da informação e comunicação (TIC) em saúde.

Não obstante, para que tais expectativas sejam alcançadas, existem desafios e muito o que se fazer para superá-los, pois não há um padrão universal de continuidade do cuidado. Ainda, faltam processos clínicos padronizados, muitos dados são capturados de maneira incompleta e com baixa qualidade, não existe um consenso sobre as taxonomias que representam toda a jornada do paciente, existem diferentes meios de financiamento do serviço, etc. (GDHP, 2019).

O Sistema Único de Saúde (SUS) é amplamente reconhecido como um modelo de cobertura universal, um dos Objetivos de Desenvolvimento Sustentável das Nações Unidas (ODS 3) para 2030⁷. Ele abrange aproximadamente 75% do atendimento de saúde no Brasil, sendo que o restante é feito por planos privados.

Semelhante ao que acontece em outros países, há um aumento do número de estabelecimentos de saúde que investiram recursos na digitalização de suas informações médicas, assim como no reconhecimento das vantagens do uso desses dados, sejam eles públicos ou privados (Bittencourt, Camacho, & Carmo Leal, 2006; Lourenção & Ferreira, 2016). Porém, ainda existem muitas dificuldades, considerando que apenas pequena parcela dos estabelecimentos possui registros eletrônicos de suas transações (Comitê Gestor da Internet no Brasil [CGI.br], 2019). Portanto, o acesso a prontuários se dá, na maioria das vezes, por meio da manipulação de papéis (CGI.br, 2018). Países como Alemanha, Austrália e Israel possuem 100% de seus profissionais médicos com acesso a prontuários eletrônicos, enquanto nos Estados Unidos e Canadá esse número é de aproximadamente 59% (Heart, Ben-Assuli, & Shabtai, 2017).

Para enfrentar esses desafios, o Brasil tem tentado criar mecanismos para proporcionar a troca de informações na saúde, tendo como pilar a Portaria n. 2.073/2011. No entanto, as duas iniciativas (o Registro Eletrônico de Saúde – RES e o Programa de Informatização das Unidades Básicas de Saúde – PIUBS) não foram colocadas em operação. Em 2019, com novos direcionamentos e tomando como base as lições aprendidas nos últimos anos, optou-se por um projeto inovador, focado em duas grandes frentes: i) criação de um ambiente tecnológico que funcionasse como uma rede e que tivesse uma abordagem nacional para propiciar a troca de informação; ii) aprimoramento das ações na atenção primária para garantir a qualidade do registro em saúde (Sousa, Cielo, Gomes, Oliveira, & Costa, 2019).

⁶ Mais informações no *website* da iniciativa GDHP. Recuperado em 25 maio, 2020, de <https://www.gdhp.org>

⁷ Mais informações no *website* da Organização das Nações Unidas no Brasil. Recuperado em 02 junho, 2020, de <https://nacoesunidas.org/pos2015/agenda2030/>

Nesse contexto, a proposta deste artigo é apresentar a jornada da criação e gestão da Rede Nacional de Dados em Saúde (RNDS) (Portaria MS n. 1.434/2020). Trata-se de uma complexa plataforma, em nuvem, que tem em seu núcleo o uso de tecnologias emergentes e que propiciará a consolidação de dados no contexto da saúde centrada no indivíduo. Permitirá, ainda, o intercâmbio e a interoperabilidade, fornecendo aos profissionais e gestores de saúde mais uma ferramenta de apoio para a continuidade da atenção e para a visão da saúde pública, respectivamente, além de empoderar o cidadão com o seu histórico clínico.

A expectativa do Ministério da Saúde (MS) é que essas ações, aliadas à adoção de melhores práticas tecnológicas e padrões internacionais, impulsionem a criação de um prontuário único de saúde centrado no paciente, considerando-o como parte integrante do programa do governo federal Conecte SUS, cuja missão é a de materializar a primeira fase da Estratégia de Saúde Digital para o Brasil (ESD).⁸

Principais características da solução

Tomando como base as iniciativas anteriores, era preciso pensar em uma proposta flexível e escalável. Flexível, porque não havia um desenho totalmente pronto ou uma proposta semelhante em que fosse possível um *benchmarking* e, certamente, seriam necessárias mudanças durante sua implementação. E escalável, porque, considerando o volume de dados e a quantidade de atores envolvidos no processo de geração e captação dos dados, o projeto deveria permitir essa expansão com muita facilidade. Esses fatores foram preponderantes para a decisão de utilizar soluções baseadas em *cloud* (Almutiry, Wills, Alwabel, Crowder, & Walters, 2013).

Entre as informações de saúde a serem trocadas e disponibilizadas, é possível citar os atendimentos clínicos, as internações, os exames realizados, os medicamentos dispensados e as vacinas aplicadas. Esse grupo de informações é chamado de Conjunto Mínimo de Dados (CMD), porque a maioria dos sistemas possuem tais informações registradas eletronicamente, face à necessidade da prestação de contas nos sistemas de informações nacionais (Barros, 2008). O CMD permite que se dê um passo na implementação e, paralelamente, que se foque na informatização dos estabelecimentos de saúde.

Decidiu-se pela utilização de tecnologias abertas e que pudessem ser facilmente replicáveis em qualquer plataforma de nuvem. A definição dos componentes tecnológicos foi baseada em experiências internacionais. A questão da segurança também foi abordada e, por isso, adotou-se uma tecnologia que tem se destacado devido à utilização no cenário econômico digital. Optou-se pelo uso do *blockchain*, sequência de blocos que contém a lista completa de registros de uma determinada transação. Características como descentralização, persistência, anonimização e auditabilidade garantem a segurança e a rastreabilidade dos eventos, condições necessárias para a troca de informação em saúde (Zheng, Xie, Dai, Chen, & Wang, 2017).

⁸ Mais informações no *website* oficial da Estratégia de Saúde Digital para o Brasil. Recuperado em 25 maio, 2020, de <https://saudedigital.saude.gov.br/a-estrategia-brasileira/>

Considerando as dimensões do país, sugeriu-se uma arquitetura em rede, composta por um conjunto de *containers*⁹ virtuais, desenhados para atender as unidades da federação, conectados entre si. Os *containers* serão responsáveis pela captação e disponibilidade de informações seguras para os prestadores de serviço em saúde, para o gestor municipal, estadual e federal. Além disso, permitirão que o cidadão acesse seu histórico clínico, possibilitando maior controle e monitoramento da evolução das suas informações em saúde.

Aspectos tecnológicos

A RNDS pode ser definida como um repositório digital de informações retrospectivas, simultâneas e prospectivas do paciente. Deve estar disponível em diferentes estabelecimentos de saúde, o que torna necessário o uso de padrões para definir não só como a informação é estruturada e representada, mas também como ela pode ser recuperada e compartilhada entre os sistemas em uso.

Nos anos 1990, mesmo com o Registro Eletrônico de Saúde (RES) mostrando sua eficiência e qualidade, era preciso encontrar uma solução para o problema da informação em silos, que é marcada pela desorganização e armazenamento em vários formatos – arquivos de escritório, portfólios de vacinação – e, quando digitalizadas, tornam praticamente impossível traçar o histórico dos pacientes e a troca de informações com outros profissionais de saúde. A solução está na interoperabilidade dos registros médicos, mas também aborda os problemas de análise longitudinal de dados e acompanhamento do paciente durante os estágios da assistência à saúde. Padrões de registro são necessários para uma identificação consistente do paciente e a segurança dos dados. Além disso, a padronização estrutural e semântica gerada pela interoperabilidade pode fornecer várias facilidades aos sistemas, tais como prescrição de medicamentos, integração de resultados de exames laboratoriais e muitos outros recursos (Kuperman, 2011).

Vários autores já exploraram a ideia de usar agentes no contexto da saúde para fornecer interoperabilidade. Mais recentemente, alguns autores exploraram o *blockchain*, propondo estratégias para melhorar a mobilidade e segurança em RES, adotando mecanismos seguros e confiáveis para acesso aos dados sensíveis sobre a saúde de um indivíduo (Isern & Moreno, 2016; Wimmer, 2014). O *blockchain* armazena a história de interações entre os pacientes e agentes de saúde, juntamente com *links* para os RES, que contêm descrições detalhadas de cada interação. Um *hash* do registro médico também é armazenado no bloco, de forma que a fidelidade do conteúdo possa ser facilmente verificada.

Ao entrar em contato com o paciente, o agente de saúde deve estar credenciado em uma ferramenta de *software* apropriada, a fim de recuperar os dados de saúde via *blockchain*. A equipe multidisciplinar de saúde pode solicitar o direito de acesso aos dados do paciente, que deve autorizar explicitamente, com exceção em casos de *break the glass* ou quando configurado para estratégia *opt out*.

⁹ Trata-se de compartimento contendo uma série de componentes tecnológicos e dados.

Uma das características relevantes na tecnologia do *blockchain* são os *smart contracts*, responsáveis por assegurar que as regras de negócio envolvidas nas transações digitais sejam cumpridas, diferente das soluções tradicionais. Eles garantem também a devolução das informações apenas aos atores autorizados que estiverem em *compliance* com as diversas leis sobre acesso e sigilo das informações. Ainda neste contexto, a estruturação das informações facilita a escalabilidade dos nós participantes da rede, reduzindo a necessidade de armazenamento centralizado e, ainda assim, garantindo a interoperabilidade.

Na arquitetura, os metadados serão utilizados no *ledger* e distribuídos entre os diversos participantes da rede. Já os documentos clínicos serão manipulados em *private data collection*, a fim de garantir a privacidade e economicidade de armazenamento do documento. Uma vez que eles serão armazenados apenas na *org custodiante* e em uma estrutura limitada de *orgs de backup*, não haverá eventual armazenamento excessivo dos documentos clínicos. Como é compartilhada no *ledger*, a *timeline* do paciente estará acessível por qualquer *org* e facilitará as consultas do paciente junto aos estabelecimentos de saúde. Os dados serão trafegados e armazenados em padrão Fast Healthcare Interoperability Resources (FHIR), onde os mais de dois mil prontuários existentes no país estruturarão as informações seguindo a ESD. No primeiro momento, serão utilizados microsserviços de transição capazes de converter os dados enviados em composição e diversificação das aplicações (CDA), *open electronic health record* (OpenEHR) e FHIR.

Com o uso do padrão FHIR para transporte e armazenamento dos dados clínicos, o MS define a infraestrutura necessária para evoluir o cuidado de saúde com a previsão de utilizar estratégias de *data analytics* e Inteligência Artificial (IA). O padrão deverá ser empregado aliado à estruturação das informações, propiciando, no futuro, o uso de estratégias de *data lake* e IA.


Estratégia de implantação

A RNDS foi criada com base nas diretrizes da ESD, construída a partir da Política Nacional de Informação e Informática em Saúde – PNIIS (Portaria MS n.589/2015) e do documento Estratégia e-Saúde para o Brasil (Resolução n.19/CIT/2017). As frentes de trabalho que envolvem o seu desenvolvimento podem ser encontradas no Plano de Ação, Monitoramento e Avaliação da Estratégia de Saúde Digital (PAM&A) 2019-2020¹⁰. A Figura 1 representa a estrutura analítica do programa.

¹⁰ Mais informações no *website* do Portal Saúde Digital. Recuperado em 02 junho, 2020, de <https://saudedigital.saude.gov.br/wp-content/uploads/2020/04/PAMA-Saude-digital.pdf>

FIGURA 1

MAPA MENTAL DA ESTRATÉGIA DE SAÚDE DIGITAL DO MINISTÉRIO DA SAÚDE, COM ÊNFASE NO PROGRAMA CONECTE SUS E NO PROJETO DA REDE NACIONAL DE DADOS EM SAÚDE (RNDS)



FONTE: MINISTÉRIO DA SAÚDE.

Com o objetivo de promover a troca de informações entre os pontos da Rede de Atenção à Saúde, permitindo a transição e continuidade do cuidado nos setores público e privado, a RNDS foi construída para constituir a desejada infovia de saúde: uma plataforma informacional de alta disponibilidade, segura e flexível, que irá favorecer o uso dos dados de forma ética, permitindo, assim, o surgimento de novos serviços, inovação, pesquisa e desenvolvimento que resultem em benefícios para o Brasil.

A estratégia de implantação da RNDS teve início com o projeto-piloto do Programa Conecte SUS no estado de Alagoas. A escolha do local foi definida considerando a diversidade dos cenários existentes, principalmente em relação aos recursos limitados de infraestrutura, como a falta de computadores, acesso à Internet, bem como o baixo índice de uso de prontuário eletrônico¹¹. O escopo da RNDS prioriza o CMD, além de visar agregar valor ao acesso à informação no histórico clínico do paciente. Definiu-se que o início do projeto em produção contemplará informações oriundas de bases de dados legadas de dois anos, como dados do Sistema de Informações Ambulatoriais (SIA), do Sistema de Informações Hospitalares (SIH), do Sistema de Informação em Saúde para a Atenção Básica (SISAB), do Sistema de Informações do Programa Nacional de Imunizações (SI-PNI), entre outros.

¹¹ Em outubro de 2019, início do projeto piloto Conecte SUS em Alagoas, 883 Equipes de Saúde da Família (ESF) utilizavam prontuário eletrônico. Em abril de 2020, 35% das ESF de Alagoas utilizavam prontuário eletrônico. Dados oficiais retirados do SISAB.

O acesso às informações se dará, a princípio, pela Plataforma Conecte SUS¹² em versões para o Cidadão, Profissional de Saúde e Gestor. O portal será o ponto central de acesso aos procedimentos realizados, permitindo aos cidadãos acompanharem a sua situação de saúde, aos profissionais de saúde acessarem os exames e o histórico clínico de seus pacientes, visando a continuidade do cuidado e, aos gestores, o acompanhamento de indicadores de saúde.

O Ministério da Saúde disponibiliza *Application Programming Interface* (API) aberta para que os *software* utilizados por estabelecimentos de saúde, como o Prontuário Eletrônico do Paciente (PEP), possam fazer sua integração à solução da RNDS em *blockchain*. Além disso, dois aplicativos foram desenvolvidos pelo MS, possibilitando o uso direto por parte dos cidadãos (Conecte SUS Cidadão – Antigo Meu digiSUS) e profissionais de saúde (Conecte SUS Profissional). As Figuras 2 e 3 ilustram as imagens do Conecte SUS Cidadão e Profissional.

FIGURA 2

APLICATIVO CONECTE SUS CIDADÃO MOSTRA OS RESULTADOS DOS EXAMES REALIZADOS PELO PACIENTE




FONTE: MINISTÉRIO DA SAÚDE.

¹² Mais informações no website do Portal Conecte SUS. Recuperado em 25 maio, 2020, de <https://ConecteSUS.saude.gov.br/home>

FIGURA 3

IMAGEM DO CONECTE SUS PROFISSIONAL, COM A VISÃO DO PROFISSIONAL DE SAÚDE SOBRE AS INFORMAÇÕES DO HISTÓRICO DO PACIENTE




FONTE: MINISTÉRIO DA SAÚDE.

Atualmente, o cenário dinâmico e de grande risco à população – gerado pela pandemia causada pelo novo coronavírus – exigiu respostas contundentes de todo o sistema de saúde, em especial do SUS, com o objetivo de coordenar as ações nacionais e orquestrar os esforços de estados, municípios, e até mesmo da Saúde Suplementar. Assim, o Programa Conecte SUS passou a priorizar suas ações para que estejam em pleno alinhamento com as prioridades nacionais de combate à COVID-19. Nesse ínterim, a RNDS passa a ser parte estruturante de um ecossistema que visa atender às necessidades de enfrentamento ao novo coronavírus.

Conforme ilustrado na Figura 4, esse ecossistema compreende camadas específicas para a segurança da informação, interoperabilidade entre sistemas, processos de notificação e vigilância em saúde, aplicativos móveis e canais de acesso.

FIGURA 4

ECOSSISTEMA DE ATENDIMENTO E DADOS EM SAÚDE PARA A COVID-19¹³*“Onion Model” da RNDS*

* LEI GERAL DE PROTEÇÃO DE DADOS

FONTE: MINISTÉRIO DA SAÚDE.

Com esse impulso, a estratégia de implantação da RNDS foi reajustada para ser disponibilizada, de forma integrada e imediata, a todos os estados brasileiros, estabelecendo-se, assim, como ferramenta fundamental para o enfrentamento da pandemia. A plataforma propiciará que os laboratórios de análises clínicas enviem os dados para a RNDS, que vai coletar, processar e disponibilizar esse conteúdo de forma segura e com garantia de privacidade para profissionais, gestores e cidadãos por meio do Portal Conecte SUS.

A Figura 5 apresenta os componentes da plataforma da RNDS, com ênfase na representação atual do CMD, serviços disponíveis, serviços de segurança e serviços planejados.

¹³ Boletim Conecte SUS Volume 4, Versão 2. Recuperado em 25 maio, 2020, de <https://saudedigital.saude.gov.br/wp-content/uploads/2020/04/Boletim-Conecte-SUS-Vol-04-Abr-2020-v024-002-novo.pdf>

FIGURA 5
COMPONENTES DA PLATAFORMA DA RNDS



FONTE: MINISTÉRIO DA SAÚDE.

Considerações finais

A RNDS foi construída visando a consolidação efetiva enquanto plataforma de serviços e informações de saúde para todo o Brasil, em benefício de cidadãos, profissionais e gestores de saúde.

Em especial, merece atenção a integração de novos serviços informacionais, utilizando tecnologias emergentes para extração de conhecimento em saúde, além de oferecer alternativas como: serviços de Telessaúde, consolidação do uso de terminologias clínicas, interoperabilidade com a Saúde Suplementar e Regulação Inteligente da Atenção à Saúde.

A RNDS é uma infovia de saúde e será um campo fértil para a inovação em Saúde Digital, abrindo a possibilidade de novos modelos de serviços, oferta de informação de qualidade, beneficiando os atores envolvidos, tanto na saúde pública como na Saúde Suplementar e no setor privado.

Ainda nesse contexto, a proposta é que todos os novos desenvolvimentos sejam apoiados por essa estratégia, fortalecendo a interoperabilidade entre os diversos sistemas existentes no âmbito da saúde. Como exemplos, podemos citar: i) sistemas de notificação de agravos; ii) prescrição eletrônica nacional; e iii) sistemas de regulação. Não obstante, espera-se que essa plataforma possibilite o uso de IA, *Analytics*, *Big Data*, Internet das Coisas e outras tecnologias para extração de conhecimento e oferta de serviços inovadores condizentes com as atuais e futuras demandas nacionais e mundiais do ecossistema global.

A RNDS ainda atuará de forma estratégica e abrangente, com a análise de dados cruzados e qualificados, permitindo a execução de ações de curto, médio e longo prazos de caráter preventivo focadas na saúde. A rede também irá contribuir para a redução dos custos e desperdícios dos serviços em saúde.

Portanto, torna-se fundamental que a governança da ESD acompanhe essa evolução, sendo cada vez mais colaborativa e inclusiva. Em consonância com a ação proposta pela Estratégia Global da OMS para a Saúde Digital, o Brasil está disposto a compartilhar sua experiência e trabalhar em conjunto com países e organizações para acelerar a digitalização da saúde no mundo, como forma de alcançar melhores níveis de atendimento à saúde da população e o bem-estar dos cidadãos, disponibilizando informações confiáveis a qualquer hora, em qualquer lugar, para quem precisa no momento em que precisa.

Referências

- Almutiry, O., Wills, G., Alwabel, A., Crowder, R., & Walters, R. (2013). Toward a framework for data quality in cloud-based health information system. *International Conference on Information Society (i-Society 2013)*, Toronto, Canadá.
- Azaria, A., Ekblaw, A., Vieira, T., & Lippman, A. (2016). MedRec: Using blockchain for medical data access and permission management. *International Conference on Open and Big Data (OBD)*, Viena, Áustria, 25-30.
- Barros, J. V. (2008). *Sistemas de informação e avaliação de desempenho hospitalar: A integração e interoperabilidade entre fontes de dados hospitalares*. Dissertação de mestrado, Faculdade de Medicina da Universidade de São Paulo, São Paulo, SP, Brasil.
- Bittencourt, S. A., Camacho, L. A. B., & Carmo Leal, M. (2006). O sistema de informação hospitalar e sua aplicação na saúde coletiva. *Cadernos de Saúde Pública*, 22(1), 19–30.
- Comitê Gestor da Internet no Brasil – CGI.br. (2018). *Pesquisa sobre o uso das tecnologias de informação e comunicação nos estabelecimentos de saúde brasileiros: TIC Saúde 2017*. São Paulo: CGI.br.
- Comitê Gestor da Internet no Brasil – CGI.br. (2019). *Pesquisa sobre o uso das tecnologias de informação e comunicação nos estabelecimentos de saúde brasileiros: TIC Saúde 2018*. São Paulo: CGI.br.
- Global Digital Health Partnership – GDHP. (2019). *Connected health: Empowering health through interoperability*. Recuperado em 17 junho, 2020, de https://www.gdhp.org/media-hub/news_feed/gdhp-reports
- Heart, T., Ben-Assuli, O., & Shabtai, I. (2017). A review of PHR, EMR and EHR integration: A more personalized healthcare and public health policy. *Health Policy and Technology*, 6(1), 20-25.
- Isern, D., & Moreno, A. (2016). A systematic literature review of agents applied in healthcare. *Journal of Medical Systems*, 40(2), 43.
- Kuperman, G. J. (2011). Health-information exchange: Why are we doing it, and what are we doing? *Journal of the American Medical Informatics Association*, 18(5), 678–682.
- Lourenção, L. G., & Ferreira, C. J. Jr. (2016). Implantação do prontuário eletrônico do paciente no Brasil. *Enfermagem Brasil*, 15(1), 44.
- Organização Mundial da Saúde – OMS. (2018). Resolução WHA71-7: 71st World Health Assembly. *Resolutions and decisions adopted by the general assembly*. Recuperado em 17 junho, 2020, de https://apps.who.int/gb/ebwha/pdf_files/WHA71/A71_7-en.pdf
- Organização Mundial da Saúde – OMS. (2019). *WHO guideline: Recommendations on digital interventions for health system strengthening*. Genebra: OMS.
- Portaria MS n. 589, de 20 de maio de 2015. (2015). Institui a Política Nacional de Informação e Informática em Saúde (PNIIS). Recuperado em 17 junho, 2020, de https://bvsms.saude.gov.br/bvs/saudelegis/gm/2015/prt0589_20_05_2015.html
- Portaria MS n. 1.434, de 28 de maio de 2020. (2020). Institui o Programa Conecte SUS e altera a Portaria de Consolidação nº 1/GM/MS, de 28 de setembro de 2017, para instituir a Rede Nacional de Dados em Saúde e dispor sobre a adoção de padrões de interoperabilidade em saúde. Recuperado em 17 junho, 2020, de http://www.in.gov.br/web/dou/-/portaria-n-1.434-de-28-de-maio-de-2020-*-259414569

Portaria MS n. 2.073, de 31 de Agosto de 2011. (2011). Regulamenta o uso de padrões de interoperabilidade e informação em saúde para sistemas de informação em saúde no âmbito do Sistema Único de Saúde, nos níveis municipal, distrital, estadual e federal, e para os sistemas privados e do setor de saúde suplementar. Recuperado em 17 junho, 2020, de https://bvsms.saude.gov.br/bvs/saudelegis/gm/2011/prt2073_31_08_2011.html

Raghupathi, W., & Raghupathi, V. (2014). Big data analytics in healthcare: Promise and potential. *Health Information Science and Systems*, 2(1), 3.

Resolução n. 19/CIT, de 22 de junho de 2017. (2017). Comissão Intergestores Tripartite do SUS. Aprova e torna público o documento Estratégia e-Saúde para o Brasil, que propõe uma visão de e-Saúde e descreve mecanismos contributivos para sua incorporação ao Sistema Único de Saúde (SUS) até 2020. Recuperado em 17 junho, 2020, de http://www.in.gov.br/materia/-/asset_publisher/Kujrw0TZC2Mb/content/id/19172500/do1-2017-07-13-resolucao-n-19-de-22-de-junho-de-2017-19172419

Sousa, A. N., Cielo, A. C., Gomes, I. C., Oliveira, J. G. Jr., & Costa, M. L. S. (2019). Estratégia e-SUS AB: Transformação digital na atenção básica do Brasil. In Comitê Gestor da Internet no Brasil – CGI.br. *Pesquisa sobre o uso das tecnologias de informação e comunicação nos estabelecimentos de saúde brasileiros: TIC Saúde 2018* (pp. 29–38). São Paulo: CGI.br.

Wimmer, H. (2014). *A multi-agent system for healthcare data privacy*. Recuperado em 17 junho, 2020, de <https://aisel.aisnet.org/cgi/viewcontent.cgi?article=1171&context=amcis2014>

Wood, C., Winton. B., Carter, K., Benkert, S., Dodd, L., & Bradley, J. (2016). *How blockchain technology can enhance EHR operability*. Recuperado em 17 junho, 2020, de https://www.hyperledger.org/wp-content/uploads/2016/10/ARKInvest_and_GEM_Blockchain_EHR_Final.pdf

Zheng, Z., Xie, S., Dai, H., Chen, X., & Wang, H. (2017). An overview of blockchain technology: Architecture, consensus, and future trends. *2017 IEEE International Congress on Big Data (BigData Congress)*, Honolulu, Estados Unidos, 557-564.

Proteção de dados na telemedicina¹

Analluza Bolivar Dallari²

Em 11 de março de 2020, a Organização Mundial da Saúde (OMS) classificou a doença causada pelo novo coronavírus, a COVID-19, como uma pandemia. Isso significa que o vírus circula em todos os continentes e há ocorrência de casos oligossintomáticos, o que dificulta a identificação. O novo coronavírus integra a família de vírus que causa infecções respiratórias, tendo sido identificado em 31 de dezembro de 2019, após casos registrados na China. A telemedicina – recurso que permite a prática do cuidado à saúde a distância, utilizando a tecnologia para o contato entre paciente e médico – é um método eficiente para auxiliar no combate da pandemia. Todavia, falta no Brasil uma regulamentação moderna, eficiente e permanente. Defasada, a Resolução CFM n. 1.643, do Conselho Federal de Medicina (CFM), atualmente vigente, foi publicada em 26 de agosto de 2002, e define a prestação desses serviços como sendo “o exercício da medicina através da utilização de metodologias interativas de comunicação audiovisual e de dados com o objetivo de assistência, educação e pesquisa em saúde”.

O Brasil enfrenta uma emergência de saúde pública e, à luz da Lei n. 13.979/2020, que versa sobre medidas para enfrentamento da emergência decorrente do novo coronavírus, a telemedicina está legalmente autorizada, na sua plenitude, para atender a situação, sem necessidade de haver uma primeira consulta presencial. É um método relevante que pode ajudar a impedir a propagação e transmissão do vírus ao evitar a sobrecarga dos serviços públicos e privados de saúde em decorrência de idas desnecessárias a hospitais e prontos-socorros.

¹ Este artigo é uma reedição atualizada do texto da autora publicado em 19 de março de 2020, intitulado “Proteção de dados na telemedicina em tempos do novo coronavírus”. Recuperado em 18 maio, 2020, de <https://www.conjur.com.br/2020-mar-19/analluza-dallari-protecao-dados-telemedicina-tempos-virus>. Ao concluir a edição da pesquisa TIC Saúde 2019, no dia 29 de agosto de 2020, o país tinha 3.846.153 casos e 120.462 óbitos.

² Advogada atuante na área da saúde e proteção de dados. Doutora e mestre em Direito Internacional e Comparado pela Faculdade de Direito da Universidade de São Paulo (USP) e especialista em Direito dos Contratos pela Fundação Getúlio Vargas (GVLaw). Atualmente, atua como advogada em empresa multinacional que presta serviços de telemedicina globalmente.

Em 19 de março de 2020, como resposta ao então ministro da Saúde, Luiz Henrique Mandetta, o Conselho Federal de Medicina editou o Ofício CFM n. 1.756/2020-Cojur, reconhecendo a possibilidade e a eticidade da utilização da telemedicina enquanto durarem as medidas de enfrentamento à COVID-19: “em caráter de excepcionalidade e enquanto durar a batalha de combate ao contágio da COVID-19”, expandindo, então, a aplicação do disposto na Resolução CFM n. 1.643/2002 para contemplar a regulamentação temporária da teleorientação, do telemonitoramento e da teleinterconsulta.

Na sequência da manifestação da autarquia federal, o Ministério da Saúde publicou, em 20 de março de 2020, a Portaria MS n. 467, que versa, em caráter excepcional e temporário, sobre as ações de telemedicina com o objetivo de regulamentar e operacionalizar as medidas de enfrentamento da emergência de saúde pública de importância internacional com base na Lei n. 13.979/2020. A Portaria esclarece que as ações de telemedicina de interação a distância podem contemplar o atendimento pré-clínico, de suporte assistencial e de consulta, monitoramento e diagnóstico, por meio de tecnologia da informação e comunicação, no âmbito do Sistema Único de Saúde (SUS), bem como na saúde suplementar e privada.

No âmbito legislativo, o Senado aprovou, em 31 de março de 2020, o Projeto de Lei n. 696, originado da Câmara dos Deputados e que libera o uso da telemedicina durante a pandemia de coronavírus no Brasil – isto é, também em caráter excepcional e temporário. O objetivo é desafogar hospitais e centros de saúde com o atendimento de pacientes a distância, por meio de recursos tecnológicos, como as videoconferências. Sancionada com dois vetos pela Presidência da República, a Lei n. 13.989, publicada em 15 de abril de 2020, versa sobre o uso da telemedicina durante a crise causada pelo coronavírus (SARS-CoV-2). O presidente vetou a competência do CFM para regulamentar a telemedicina após o fim da pandemia, argumentando que se trata de matéria que deve ser regulada em lei, ao menos em termos gerais. Vetou também a validade da emissão de receitas e atestados médicos a distância sem a assinatura digital com certificado ICP-Brasil.

Observa-se que a atual conjuntura legal permite a prática da telemedicina na sua plenitude, enquanto perdurar o estado de calamidade pública. De todo modo, a Ética e o Direito ainda não traçaram com exatidão o caminho seguro a ser trilhado, especialmente em relação à privacidade, segurança da informação, sigilo profissional e responsabilidade do médico quanto ao armazenamento e compartilhamento de dados sensíveis de saúde. Este artigo visa traçar algumas reflexões sobre a proteção de dados na telemedicina em tempos do novo coronavírus e debater alguns aspectos práticos que não foram abordados pelo contexto legal atual expressamente, sem nenhuma intenção de esgotar o tema.

Contextualizando a telemedicina

Nos termos da Lei n. 3.268/1957, cabe ao Conselho Federal de Medicina disciplinar o exercício profissional da categoria e zelar pela boa prática da atividade no país. A Resolução CFM n. 2.217/2018, elaborada pelo conselho, aprovou o mais recente Código de Ética Médica, em vigor desde o dia 30 de abril de 2019. Ele estabelece, no Parágrafo 1º do Artigo 37, que “o atendimento médico a distância, nos moldes da telemedicina ou de outro método, dar-se-á sob regulamentação do Conselho Federal de Medicina”. Como já observado, embora ultrapassada, a Resolução CFM

n. 1.643/2002, da mesma autarquia, permanece em vigor. Ela define e disciplina a prestação de serviços por telemedicina, mas proíbe a integralidade deste exercício, permitindo apenas a realização de videoconferência durante procedimento para que o médico obtenha a opinião de colegas em ação executada sempre com a presença de um médico ao lado do paciente.

Existe um claro descompasso entre a normativa vigente e a realidade tecnológica atual. Em 2002, não havia *smartphone* ou aplicações de chamada de voz como se conhece atualmente, sem falar na qualidade da transmissão *on-line* de informações, muito inferior em comparação com a disponível hoje. Os conselheiros efetivos da autarquia decidiram revogar a Resolução CFM n. 2.227/2018, que definia e disciplinava a telemedicina como forma de prestação de serviços médicos mediados por tecnologias, o que ocorreu 30 dias após a sua publicação no Diário Oficial da União³. Em seguida ao recuo, foi aberto um ciclo de consultas públicas para debater novamente o tema. Elas já estão encerradas e a publicação de novo diploma normativo por parte do CFM é aguardado⁴. Ele poderá substituir o entendimento, hoje ultrapassado, trazido pela Resolução n. 1.643/2002 sobre a telemedicina.

Com a pandemia e à luz da Lei n. 13.989/2020, o cenário ainda é incerto. Conforme mencionado, o presidente da República vetou o Artigo 6º do projeto de lei que resultou no diploma que determinava ao Conselho Federal de Medicina a regulamentação da telemedicina após o período da crise ocasionada pelo coronavírus (SARS-CoV-2). Para o presidente, a regulação das atividades médicas por meio de telemedicina, após o fim da atual pandemia, é matéria que deve ser regulada em lei, ao menos em termos gerais, como se extrai do Artigo 5º, Incisos II e XIII, da Constituição Federal. Provavelmente, caberá ao CFM regulamentar, posteriormente, o que a possível nova lei vai estabelecer.

Certo é que a pandemia – e o cenário jurídico atualizado por ela – mostrou que a telemedicina praticada integralmente, abrangendo o atendimento pré-clínico, de suporte assistencial e de consulta, monitoramento, diagnóstico e prescrição, por meio de tecnologia da informação e comunicação, é um caminho sem volta, em sintonia com os avanços das tecnologias digitais e eletrônicas, hoje tão dinâmicas e presentes no cotidiano.

Proteção de dados na telemedicina e a ética médica

O Artigo 5º, Inciso XIII, da Constituição Federal, assegura como direito fundamental o livre exercício de qualquer trabalho, ofício ou profissão, atendidas as qualificações profissionais que a lei estabelecer. Exercida de maneira ética e legal, e respeitando-se a liberdade e privacidade do paciente, a telemedicina não viola a

³ Conselheiros do CFM revogam a Resolução n. 2.227/2018, que trata da telemedicina por meio da Resolução CFM n. 2.228/2019, publicada no Diário Oficial da União em 06 de março de 2019. Nota divulgada em 06 de fevereiro de 2019. Recuperado em 14 fevereiro, 2020, de https://portal.cfm.org.br/index.php?option=com_content&view=article&id=28096:2019-02-22-15-13-20&catid=3. A revogação se deu por meio da Resolução n. 2.228/2018, que restabeleceu a vigência da Resolução n. 1.643/2002, que havia sido revogada pela Resolução n. 2.227/2018. Situação curiosa de reprivatização. É que o Parágrafo 3º da Lei de Introdução às normas do Direito Brasileiro, redação dada pela Lei n. 12.376/2010, ao Decreto-Lei n. 4.657/1942, dispõe que "salvo disposição em contrário, a lei revogada não se restaura por ter a lei revogadora perdido a vigência".

⁴ As novas regras não haviam sido publicadas até a finalização da edição desta pesquisa, no final do primeiro semestre de 2020.

relação médico-paciente e ainda oferece benefícios sociais. Ainda que temporária, a Lei n. 13.989/2020 autoriza sua prática, entendendo-a como sendo o exercício da medicina mediado por tecnologias para fins de assistência, pesquisa, prevenção de doenças e lesões e promoção de saúde. Contudo, trata-se de uma lei concisa, que não contorna aspectos práticos com profundidade. Estabelece que cabe ao médico o dever de informar ao paciente todas as limitações inerentes ao uso da telemedicina, tendo em vista a impossibilidade de realização de exame físico durante a consulta. Também preconiza que a prestação desse serviço seguirá os padrões normativos e éticos usuais do atendimento presencial.

Por outro lado, a Lei n. 13.989/2020 não aborda questões sobre a responsabilidade do médico, proteção de dados e segurança da informação; necessidade, ou não, de manter inscrição secundária no estado em que se situar o paciente atendido por meio de ferramenta tecnológica; e determinação do local da prestação do serviço para fins tributários.

A adequada redação do Termo de Consentimento Livre e Esclarecido (TCLE), a ser assinado pelo paciente, e a atualização constante de ferramentas de segurança da informação por parte das empresas médicas que oferecem serviços de telemedicina, são pontos que devem orientar a atividade para garantir a conformidade legal e ética da empresa, de modo a evitar as graves sanções previstas pelo Artigo 52 da Lei Geral de Proteção de Dados Pessoais (LGPD) e também pelo Código de Ética Médica (Lei n. 13.709/2018; Resolução CFM n. 2.217/2018). Ao avaliar a conduta do profissional, o Conselho Regional de Medicina pode aplicar as penas previstas na Lei n. 3.268/1957.⁵

Já é realidade que empresas de tecnologia e prestadoras de serviços médicos desenvolvem *software* e plataformas digitais com soluções voltadas à teletriagem, teleorientação, telelaudos, teleconsultas com teleprescrição e emissão de segunda opinião médica por meio de plataformas e aplicativos que podem também utilizar Inteligência Artificial. Essas empresas são obrigadas a respeitar a legislação que versa sobre privacidade e segurança da informação, como a LGPD, o Código de Ética Médica e outras resoluções pertinentes do CFM.

Dados obtidos durante uma consulta de telemedicina devem ser protegidos por meio de medidas de segurança da informação apropriadas e atualizadas constantemente para evitar acesso não autorizado. Para isso, a empresa pode utilizar recursos como detecção de vulnerabilidades de *hardware* e *software*, efetuar *backups* periódicos e realizar controles de acesso, tanto físico quanto lógico (controle de acesso com travas especiais nas portas e biometria, *firewall*, *antimalware* e dupla criptografia para banco de dados). Senhas não podem ser compartilhadas, nem mesmo entre os médicos. Uma política de gestão de riscos apropriada, com a conscientização interna das equipes e treinamento frequente, pode ajudar a evitar o risco de incidentes de segurança causados internamente por negligência ou até mesmo por dolo.⁶

⁵ De acordo ao Artigo 22 da referida lei, as penas disciplinares aplicáveis pelos Conselhos Regionais aos seus membros são as seguintes: a) advertência confidencial em aviso reservado; b) censura confidencial em aviso reservado; c) censura pública em publicação oficial; d) suspensão do exercício profissional por até 30 (trinta) dias; e) cassação do exercício profissional, *ad referendum*, pelo Conselho Federal.

⁶ A autora registra a colaboração de Fernanda Brandão, analista de qualidade e segurança da informação, pelos esclarecimentos com respeito à ISO 27001 (ABNT NBR ISO/IEC 27001:2006), intitulada "Tecnologia da informação – Técnicas de segurança – Sistemas de gestão da segurança da informação – Requisitos", publicada em outubro de 2005 pela International Organization for Standardization (ISO) e pela International Electrotechnical Commission (IEC).

Para realizar a prescrição, o médico deve usar assinatura eletrônica, por meio de certificado digital emitido pela Infraestrutura de Chaves Públicas Brasileira (ICP-Brasil, modelo A3, cartão ou *token*), garantindo a autenticidade, a integridade e a validade jurídica de documentos em forma eletrônica, à luz da Medida Provisória n. 2.200-2/2001⁷. Atualmente, existem 17 autoridades certificadoras (AC) credenciadas à ICP-Brasil, como o Serviço Federal de Processamento de Dados (Serpro), Caixa Econômica Federal ou Receita Federal.⁸

Nesse sentido, ao vetar o Artigo 2º da Lei n. 13.989/2020, o presidente da República argumentou que a propositura legislativa, ao dispor sobre a validade das receitas médicas apresentadas em suporte digital, desde que estas possuísem assinatura eletrônica ou digitalizada do profissional que realizou a prescrição, sendo dispensada sua apresentação em meio físico, ofenderia o interesse público e geraria risco sanitário à população. Isso porque equipara a validade e autenticidade de um mero documento digitalizado e de fácil adulteração ao documento eletrônico com assinatura digital com certificados ICP-Brasil como meio hábil para a prescrição de receitas de controle especial e nas prescrições de antimicrobianos. Isso poderia ocasionar o colapso no sistema atual de monitoramento de venda de medicamentos controlados, abrindo espaço para uma disparada no consumo de opioides e outras drogas do gênero, em descompasso com as normas técnicas de segurança e controle da Agência de Vigilância Sanitária (Anvisa)⁹. Ainda assim, nem todas as farmácias do Brasil estão aptas para realizarem a validação e dispensação da prescrição eletrônica, impressa ou não, salvo as grandes redes.

A partir da Resolução CFM n. 2.227/2019¹⁰ entendia-se que, para assegurar um dos princípios éticos fundamentais na relação com os pacientes, como o respeito ao sigilo médico, todos os atendimentos deveriam ser gravados e guardados, com envio de um relatório ao paciente. Tudo com sua concordância e autorização expressa, ou de seu representante legal – por meio de consentimento informado, livre e esclarecido, por escrito e assinado. A conjuntura legal, atualmente em vigor, no entanto, não obriga a gravação e armazenamento da assistência médica mediada por tecnologia.

A redação do TCLE que será disponibilizada ao paciente deve ser feita com muita atenção, de modo a salvaguardar os direitos previstos no Artigo 18 da LGPD¹¹, assim

⁷ Não convertida em lei conforme a Emenda Constitucional n. 32, de 11 de setembro de 2001: Art. 2º - As medidas provisórias editadas em data anterior à da publicação desta emenda continuam em vigor até que medida provisória ulterior as revogue explicitamente ou até deliberação definitiva do Congresso Nacional.

⁸ É possível conferir a lista completa no *website* do Instituto Nacional de Tecnologia da Informação (ITI). Recuperado em 17 abril, 2020, de <https://www.iti.gov.br/icp-brasil/estrutura>

⁹ A possibilidade de assinatura digital com certificação ICP-Brasil não se aplica a outros receituários eletrônicos de medicamentos controlados, como os talonários de Notificação de Receita A (NRA), Notificação de Receita Especial para Talidomida, Notificação de Receita B e B2 e Notificação de Receita Especial para Retinoides de uso sistêmico.

¹⁰ Revogada pela Resolução CFM n. 2.228/2019, restaurando a vigência da Resolução CFM n. 1.643/2002.

¹¹ Artigo 18 da LGPD: O titular dos dados pessoais tem direito a obter do controlador, em relação aos dados do titular por ele tratados, a qualquer momento e mediante requisição: I - confirmação da existência de tratamento; II - acesso aos dados; III - correção de dados incompletos, inexatos ou desatualizados; IV - anonimização, bloqueio ou eliminação de dados desnecessários, excessivos ou tratados em desconformidade com o disposto nesta Lei; V - portabilidade dos dados a outro fornecedor de serviço ou produto, mediante requisição expressa, de acordo com a regulamentação da autoridade nacional, observados os segredos comercial e industrial; VI - eliminação dos dados pessoais tratados com o consentimento do titular, exceto nas hipóteses previstas no Artigo 16 desta Lei; VII - informação das entidades públicas e privadas com as quais o controlador realizou uso compartilhado de dados; VIII - informação sobre a possibilidade de não fornecer consentimento e sobre as consequências da negativa; IX - revogação do consentimento, nos termos do § 5º do art. 8º desta Lei.

como esclarecer em que circunstâncias os dados poderão permanecer armazenados de forma segura pelo controlador, à luz do Artigo 16, Inciso I, da LGPD¹², dispensando-se a eliminação. Para efeitos da LGPD¹³, considera-se consentimento “a manifestação livre, informada e inequívoca pela qual o paciente concorda com o tratamento de seus dados pessoais para uma finalidade determinada”. No caso de um serviço prestado *on-line*, o TCLE não será aprovado pelo paciente na forma de assinatura em documento físico, sendo que todo cuidado é preciso para demonstrar a manifestação inequívoca de vontade do paciente, para o fim de amenizar o risco de vícios e, consequentemente, a nulidade. É que a manifestação de vontade genérica e sem restrições de qualquer natureza autorizando o tratamento de dados é expressamente vedada por lei. No caso de tratamento de dados de saúde, cabe salientar que o paciente é vulnerável, por conta da ausência de liberdade substancial no momento da manifestação da vontade e por se tratar de dados de natureza personalíssima e potencialmente discriminatória.¹⁴

O dever de sigilo profissional estende-se às equipes assistenciais envolvidas no atendimento, como enfermeiros, nutricionistas e farmacêuticos. Ninguém da empresa, além do médico e desses profissionais, pode acessar o prontuário sem o consentimento inequívoco do paciente. Por outro lado, a LGPD prevê bases legais taxativas para o tratamento de dados pessoais sensíveis sem o consentimento do titular-paciente.

O Parágrafo 4º do Artigo 11 da LGPD veda a comunicação ou o uso compartilhado entre controladores de dados pessoais sensíveis de saúde com o objetivo de obter vantagem econômica. Contudo, abre exceções, como nas hipóteses relativas à prestação de serviços de saúde, de assistência farmacêutica e de assistência à saúde, incluídos os serviços auxiliares de diagnose e terapia, desde que em benefício dos interesses dos titulares de dados, proibida a prática de seleção de riscos, e para permitir as transações financeiras e administrativas resultantes do uso e da prestação desses serviços (Artigo 11, Parágrafo 4º, Inciso II, da LGPD). Ainda assim, quando estritamente necessária, a comunicação e o compartilhamento devem ser realizados respeitando-se os princípios de finalidade, necessidade, transparência, proporcionalidade, segurança e não discriminação.

Algumas empresas, não necessariamente com natureza jurídica de prestação de serviços de saúde, contratam serviços de telemedicina como um benefício aos seus colaboradores. Importa frisar que dados de saúde desse beneficiário-paciente levantados durante as teleconsultas não podem ser compartilhados com o empregador sem base legal, a não ser mediante expresso consentimento do usuário. É que, não raro, essas empresas têm a expectativa de receberem um relatório contendo dados mínimos relativos às teleconsultas, seja para avaliar o serviço prestado, dar continuidade à assistência de seu colaborador ou, ainda, avaliar uma possível demissão, o que seria uma prática de seleção de riscos e discriminação. Isso é proibido pela legislação que

¹² Artigo 16 da LGPD: Os dados pessoais serão eliminados após o término de seu tratamento, no âmbito e nos limites técnicos das atividades, autorizada a conservação para as seguintes finalidades: I - cumprimento de obrigação legal ou regulatória pelo controlador.

¹³ Artigo 5º, Inciso XII, da LGPD.

¹⁴ Artigo 11 do Código Civil: Com exceção dos casos previstos em lei, os direitos da personalidade são intransmissíveis e irrenunciáveis, não podendo o seu exercício sofrer limitação voluntária.

trata sobre proteção de dados, como a LGPD, e pelo Código de Ética Médica. Sem base legal ou sem o consentimento prévio, o tráfego não pode acontecer nem mesmo entre médicos dessas empresas.

O Artigo 6º da Lei n. 13.979/2020 preceitua a seguinte disposição: “É obrigatório o compartilhamento entre órgãos e entidades da administração pública federal, estadual, distrital e municipal de dados essenciais à identificação de pessoas infectadas ou com suspeita de infecção pelo coronavírus, com a finalidade exclusiva de evitar a sua propagação”. O Parágrafo 2º do mesmo artigo prevê que o Ministério da Saúde manterá dados públicos e atualizados sobre os casos de coronavírus confirmados, suspeitos e em investigação, que se relacionam à situação de emergência pública sanitária, resguardando o direito ao sigilo das informações pessoais. Esse compromisso com a privacidade do paciente é reiterado pelo Artigo 13 da Portaria MS n. 356, de 11 de março de 2020, do Ministério da Saúde. O compartilhamento dessas informações por pessoas jurídicas de direito privado, quando os dados forem solicitados por autoridade sanitária – a notificação compulsória – deve ser realizado de maneira que se resguarde a segurança da informação, em pleno respeito à dignidade, aos direitos humanos e às liberdades fundamentais dos indivíduos.

Conclusão

É um equívoco afirmar que a telemedicina, conduzida de forma ética e que tenha como prisma resguardar o sigilo, a privacidade e a segurança da informação, substituirá o médico. Há, sim, a conveniência de regulamentar a prática, de modo que se tenha compreensão das possibilidades e dos limites do exercício desta atividade de forma mais compatível com a realidade digital atual. Para o professor Chao Lung Wen¹⁵, a telemedicina não objetiva substituir a prática médica, mas ampliar o ecossistema de saúde conectada e integrar, com maior eficiência, todo o sistema de saúde. Esse entendimento deve ser também difundido nas faculdades de medicina para preparar os profissionais à nova realidade.

São muitas as vantagens da telemedicina exercida de maneira ética e legal. A utilização de recursos de tecnologias interativas para possibilitar cuidados integrados e humanizados pode melhorar e intensificar o acesso aos pacientes, melhorar a logística da cadeia de saúde, além de promover a saúde, ajudar a prevenir doenças e proteger o paciente da exposição a riscos desnecessários causados por deslocamentos que podem ser evitados. Pessoas podem ser diagnosticadas e orientadas sem precisarem ir ao pronto atendimento, onde ficariam vulneráveis a infecções mais graves. Ademais, pode-se evitar que o paciente seja submetido a exames invasivos e dispensáveis, poupando-o de sofrimento e riscos, além de desafogar o sistema público e as operadoras privadas de saúde.

¹⁵ Fala do professor Chao Lung Wen, da Faculdade de Medicina da Universidade de São Paulo (FMUSP), na audiência pública “Telemedicina, novas tecnologias e inovação em saúde”, na Comissão de Seguridade Social e Família da Câmara dos Deputados, transmitida ao vivo em 28 de novembro de 2019. Recuperado em 20 fevereiro, 2020, de https://www.youtube.com/watch?v=8aWHEJg_RWc&t=921s

No âmbito do Sistema Único de Saúde (SUS), a telemedicina pode ajudar a diminuir filas de exames e cirurgias e garantir o acesso à saúde a quem realmente precisa no momento, visto que reduz o tempo de espera nos serviços de urgência. Desse modo, pronto atendimentos e hospitais podem cumprir sua função de atender casos mais urgentes e complexos. A telemedicina também viabiliza a transmissão do conhecimento, pois pode ensinar práticas especializadas a profissionais alocados em serviços de saúde nos locais mais distantes do território nacional.

Até o momento¹⁶ não se sabe por quanto tempo perdurará o estado de calamidade pública decretado face à emergência de saúde pública de importância internacional decorrente do coronavírus. Foi preciso uma pandemia para o Conselho Federal de Medicina reconhecer, ainda que temporariamente, a importância da telemedicina em sua plenitude como meio de combate à disseminação do novo coronavírus e incentivo ao isolamento social. O Ministério da Saúde chamou atenção e o Congresso Nacional aprovou rapidamente o projeto de lei que versa sobre a telemedicina. Em mensagem de veto, o presidente da República afirmou que a regulação das atividades médicas por meio de telemedicina após o fim da atual pandemia é matéria que deve ser regulada em lei, ao menos em termos gerais, declinando a competência do CFM para regulamentar esta prática. Esse cenário indica que sua regulamentação, feita de forma que atenda à realidade digital atual, é um caminho sem volta.

¹⁶ Considerando a data de entrega deste artigo à pesquisa TIC Saúde 2019, em 17 de maio de 2020.

Referências

- Constituição da República Federativa do Brasil de 1988.* (1998). Brasília, DF. Recuperado em 17 maio, 2020, de http://www.planalto.gov.br/ccivil_03/constituicao/constituicao.htm
- Lei Geral de Proteção de Dados Pessoais – LGPD.* Lei n. 13.709, de 14 de agosto de 2018. (2018). Dispõe sobre o tratamento de dados pessoais, inclusive nos meios digitais, por pessoa natural ou por pessoa jurídica de direito público ou privado, com o objetivo de proteger os direitos fundamentais de liberdade e de privacidade e o livre desenvolvimento da personalidade da pessoa natural. Brasília, DF. Recuperado em 25 julho, 2018, de http://www.planalto.gov.br/ccivil_03/_Ato2015-2018/2018/Lei/L13709.htm
- Lei n. 3.268, de 30 de setembro de 1957.* (1957). Dispõe sobre os Conselhos de Medicina, e dá outras providências. Brasília, DF. Recuperado em 17 maio, 2020, de http://www.planalto.gov.br/ccivil_03/leis/L3268.htm
- Lei n. 12.376, de 30 de dezembro de 2010.* (2010). Altera a ementa do Decreto-Lei no 4.657, de 4 de setembro de 1942, sobre a Lei de Introdução às normas do Direito Brasileiro. Brasília, DF. Recuperado em 17 maio, 2020, de http://www.planalto.gov.br/ccivil_03/_Ato2007-2010/2010/Lei/L12376.htm
- Lei n. 13.979, de 6 de fevereiro de 2020.* (2020). Dispõe sobre as medidas para enfrentamento da emergência de saúde pública de importância internacional decorrente do coronavírus responsável pelo surto de 2019. Brasília, DF. Recuperado em 17 maio, 2020, de http://www.planalto.gov.br/ccivil_03/_ato2019-2022/2020/lei/L13979.htm
- Lei n. 13.989, de 15 de abril de 2020.* (2020). Dispõe sobre o uso da telemedicina durante a crise causada pelo coronavírus (SARS-CoV-2). Brasília, DF. Recuperado em 17 maio, 2020, de http://www.planalto.gov.br/ccivil_03/_ato2019-2022/2020/Lei/L13989.htm
- Medida Provisória n. 2.200-2, de 24 de agosto de 2001.* (2001). Institui a Infra-Estrutura de Chaves Públicas Brasileira - ICP-Brasil, transforma o Instituto Nacional de Tecnologia da Informação em autarquia, e dá outras providências. Brasília, DF. Recuperado em 17 maio, 2020, de http://www.planalto.gov.br/ccivil_03/MPV/Antigas_2001/2200-2.htm
- Ofício CFM n. 1.756, de 19 de março de 2020.* (2020). Brasília, DF. Recuperado em 17 maio, 2020, de http://portal.cfm.org.br/images/PDF/2020_oficio_telemedicina.pdf
- Portaria MS n. 356, de 11 de março de 2020.* (2020), do Ministério da Saúde. Dispõe sobre a regulamentação e operacionalização do disposto na Lei n. 13.979, de 6 de fevereiro de 2020, que estabelece as medidas para enfrentamento da emergência de saúde pública de importância internacional decorrente do coronavírus (COVID-19). Recuperado em 17 maio, 2020, de <http://www.in.gov.br/en/web/dou/-/portaria-n-356-de-11-de-marco-de-2020-247538346>
- Portaria MS n. 467, de março de 2020.* (2020). Dispõe, em caráter excepcional e temporário, sobre as ações de Telemedicina, com o objetivo de regulamentar e operacionalizar as medidas de enfrentamento da emergência de saúde pública de importância internacional previstas no art. 3º da Lei n. 13.979, de 6 de fevereiro de 2020, decorrente da epidemia de COVID-19. Brasília, DF. Recuperado em 17 maio, 2020, de http://www.planalto.gov.br/CCIVIL_03/Portaria/PRT/Portaria%20n%C2%BA%20467-20-ms.htm

Projeto de Lei n. 696, de 31 de março de 2020. (2020). Dispõe sobre o uso da telemedicina durante a crise causada pelo coronavírus (SARS-CoV-2). Brasília, DF. Recuperado em 17 maio, 2020, de <https://www25.senado.leg.br/web/atividade/materias/-/materia/141263>

Resolução CFM n. 1.643, de 26 de agosto de 2002. (2002). Define e disciplina a prestação de serviços através da Telemedicina. Brasília, DF. Recuperado em 17 maio, 2020, de <https://sistemas.cfm.org.br/normas/visualizar/resolucoes/BR/2002/1643>

Resolução CFM n. 2.217, de 1 de novembro de 2018. (2018). Aprova o Código de Ética Médica. Brasília, DF. Recuperado em 17 maio, 2020, de http://www.in.gov.br/materia/-/asset_publisher/Kujrw0TZC2Mb/content/id/48226289/do1-2018-11-01-resolucao-n-2-217-de-27-de-setembro-de-2018-48226042

Resolução CFM n. 2.227, de 14 de dezembro de 2018. (2018). Define e disciplina a telemedicina como forma de prestação de serviços médicos mediados por tecnologias. Brasília, DF. Recuperado em 17 maio, 2020, de <https://sistemas.cfm.org.br/normas/visualizar/resolucoes/BR/2018/2227>

Resolução CFM n. 2.228, de 6 de março de 2019. (2019). Revoga a Resolução CFM n. 2.227, publicada no D.O.U. de 6 de fevereiro de 2019, Seção I, p.58, a qual define e disciplina a telemedicina como forma de prestação de serviços médicos mediados por tecnologias, e restabelece expressamente a vigência da Resolução CFM n. 1.643/2002. Brasília, DF. Recuperado em 17 maio, 2020, de <https://sistemas.cfm.org.br/normas/visualizar/resolucoes/BR/2019/2228>

Uso da Inteligência Artificial para otimizar o uso de dados de Registros Eletrônicos de Saúde

Shamim Nemat¹, Supreeth P. Shashikumar², Fatemeh Amrollahi³, Tsung-Ting Kuo⁴ e Lucila Ohno-Machado⁵

A Inteligência Artificial na medicina

Em 2007, o Institute of Medicine, atualmente conhecido como National Academy of Medicine (Academia Nacional de Medicina), nos Estados Unidos, publicou o documento “*The Learning Healthcare System*” (em português, Sistema de Saúde de Aprendizagem), que apresenta uma visão para sistemas de saúde como ambientes onde “a ciência, a informática, as motivações e a cultura estão alinhados para o aprimoramento contínuo e a inovação, com as melhores práticas integradas sem perturbação no processo de cuidado [do paciente] e de novos conhecimentos aprendidos como um subproduto integral dessa experiência” (Olsen, Aisner, & McGinnis, 2007). Na última década, várias correntes e inovações tecnológicas nos aproximaram da visão de um

¹ Professor assistente na Universidade da Califórnia San Diego (UCSD). PhD em Engenharia Elétrica e Ciência da Computação pelo Instituto de Tecnologia de Massachussets (MIT) em 2013. Durante o período no MIT, ganhou uma bolsa de pesquisa Ruth L. Kirschstein National Research Award (NRSA) no Brigham and Women's Hospital e Harvard Medical School. Membro do grupo Sistemas Probabilísticos Inteligentes de Harvard (Harvard Intelligent Probabilistic Systems) por meio da bolsa da Fundação James S. McDonnell (JSMF) de pós-doutorado em sistemas complexos.

² Pesquisador na UCSD. PhD em Engenharia Elétrica e Computacional pelo Instituto de Tecnologia da Georgia em 2020. A pesquisa de seu PhD focou o desenvolvimento de modelos de aprendizagem de máquina generalizáveis para a previsão de eventos clínicos adversos em unidades de terapia intensiva (UTI). Sua área de pesquisa atual é sobre análise preditiva em terapia intensiva e na análise de série histórica multidimensional utilizando o processamento avançado de sinais e técnicas de aprendizagem profunda.

³ Doutoranda pela UCSD e mestre em Ciência da Computação e Informática Biomédica pela Emory University em 2018. Durante seu mestrado, desenvolveu uma plataforma aberta para a previsão em tempo real de sepse com base em dados multidimensionais extraídos de prontuários eletrônicos e monitores de beira de leito em formato HL7 ou FHIR.

⁴ Professor assistente de Medicina no Departamento de Saúde de Informática Biomédica (DBMI) da UCSD. PhD pela Universidade Nacional de Taiwan (NTU) no Instituto de Networking e Multimídia. Antes de se tornar parte do corpo docente, recebeu seu pós-doutorado pela UCSD DBMI e teve sua excelência acadêmica reconhecida por meio do prêmio UCSD Chancellor's Outstanding Postdoctoral Scholar Award.

⁵ Médica formada pela Faculdade de Medicina da Universidade de São Paulo e PhD em Ciências da Informação Médica e Ciência da Computação pela Universidade de Stanford. Reitora associada do Departamento de Informática e Tecnologia e presidente fundadora do Departamento de Saúde de Informática Biomédica da UCSD. Membro das instituições americanas National Academy of Medicine, American College of Medical Informatics, American Institute for Medical and Biological Engineering, e American Society for Clinical Investigation.

sistema de saúde de aprendizado contínuo. Primeiro, com o aumento da adoção de Registros Eletrônicos de Saúde (RES) e do uso clínico de *Big Data* (Luo, Wu, Gopukumar, & Zhao, 2016; Bates, Saria, Ohno-Machado, Shah, & Escobar, 2014), o setor de saúde começou a alcançar outros segmentos que aproveitam efetivamente os dados para otimizar a satisfação do consumidor. Em segundo lugar, a ideia de troca de informações de saúde por meio de uma infraestrutura segura e interoperável para o compartilhamento de dados tornou-se tema fundamental, sobretudo diante da promessa de uma nova indústria de saúde digital que tem a expectativa de ultrapassar US\$ 504,4 bilhões em 2025 (Ugalmugle & Devgire, 2019). O terceiro ponto é que o ressurgimento excepcional da Inteligência Artificial (IA) e seu impacto na automação resultou em um interesse crescente na aplicação de técnicas avançadas de análise para uma série de aplicações de saúde (Patel *et al.*, 2009; Jiang *et al.*, 2017; He *et al.*, 2019).

Os primeiros sistemas de apoio à decisão clínica (SADC) eram baseados no conhecimento, isso porque implementavam regras produzidas por especialistas da área em computadores e eram ajustadas ao longo do tempo para apoiar as decisões clínicas. Exemplos desses sistemas baseados em regras incluem o INTERNIST (Miller, McNeil, Challinor, Masarie, & Myers, 1986), uma base de conhecimento contendo cerca de 500 doenças e mais de 3 mil manifestações clínicas, e o MYCIN (Shortliffe & Fagan, 1985), um sistema especializado que identificava bactérias que causam infecções severas, como bacteremia e meningite, para recomendar antibióticos com dosagens ajustadas ao peso do paciente. Na última década, técnicas de IA, como o aprendizado de máquina – AM (do inglês, *machine learning*) e a aprendizagem profunda – AP (do inglês, *deep learning*) vêm ganhando cada vez mais atenção e aplicações na medicina clínica (Ohno-Machado, 2018a; Dilsizian & Siegel, 2014; Johnson *et al.*, 2016a; Ravi *et al.*, 2017; Esteva *et al.*, 2019; Rajkomar *et al.*, 2018; Topol, 2019). Nessas metodologias, os modelos utilizam dados digitalizados (*inputs*) para prever resultados especificados (*outputs*). Dados clínicos podem ser coletados em diferentes intervalos de tempo (por exemplo, dados sobre medicações e exames laboratoriais do RES) ou de forma contínua (por exemplo, dados de sinais vitais advindos de sensores de monitoramento remoto). O aprendizado supervisionado é uma grande área do AM, que inclui o mapeamento entre dados e um rótulo de *output*, como mortalidade ou rehospitalização. O objetivo do aprendizado (no contexto do AM) é conseguir derivar as características (ou representações de dados) que mais preveem os marcadores específicos considerados. Em razão da variedade e da quantidade de dados de pacientes atualmente disponíveis, o AM e a AP são capazes de computar interações complexas ou relações temporais entre dados de *input* que clínicos e pacientes tendem a desconsiderar (Shashikumar, Josef, Sharma, & Nemati, 2019).

De fato, o uso do AM para realizar a triagem de pacientes com doenças agudas e crônicas já tem demonstrado resultados iniciais promissores. Sendak *et al.* (2020) realizaram uma revisão abrangente dos algoritmos do AM aplicados a tarefas de apoio a decisões clínicas, com ênfase nos modelos que foram integrados aos fluxos de trabalhos clínicos. Alguns dos exemplos mais comuns de SADC incluem a previsão precoce da sepse (Shashikumar *et al.*, 2019; Nemati, *et al.*, 2018; Giannini *et al.*, 2019) e da insuficiência renal aguda (IRA) (Connell *et al.*, 2019; Tangri *et al.*, 2011), bem como algoritmos para triagem em departamentos de emergência (Levin *et al.*, 2018), previsão de parada cardíaca (Churpek *et al.*, 2016), avaliação de risco de queda para pacientes

hospitalizados (Cho, Boo, Chung, Bates, & Dykes, 2019), previsão de rehospitalização em até 30 dias (Hao *et al.*, 2015) e de rehospitalização para pacientes com doença pulmonar obstrutiva crônica (DPOC) (Min, Yu, & Wang, 2019), entre outros.

Enquanto os métodos do AM têm fornecido à comunidade uma riqueza de conhecimento sobre como aprimorar o cuidado com o paciente, vários desafios têm impedido a adoção mais ampla desses sistemas na prática clínica. Esses desafios incluem: 1) falta de transparência e explicações (“caixa-preta”); 2) questões relativas à generalização e portabilidade de algoritmos do AM; e 3) a acessibilidade dos dados e a privacidade de pacientes. Este artigo avalia algumas soluções possíveis para tais desafios por meio de um estudo de implementação de um algoritmo do AM no contexto da previsão precoce, em tempo real, da sepse.

Um estudo de caso de previsão de sepse

A sepse está entre as principais causas de morbidade e mortalidade entre pacientes críticos e é a condição mais onerosa em termos de despesas em saúde. O choque séptico ocorre quando o corpo reage de forma exagerada a uma infecção, desencadeando uma resposta imunológica desregulada e causando danos graves aos tecidos que podem levar à falência de órgãos e à morte. Atualmente, ela é um dos problemas críticos da medicina devido à sua complexidade do ponto de vista fisiopatológico, clínico e terapêutico. A sepse é uma causa significativa de hospitalização e um problema especialmente comum em unidades de terapia intensiva (UTI), pois afeta aproximadamente 25% dos pacientes internados. Nos Estados Unidos, o Healthcare Cost and Utilization Project - HCUP (Projeto de Custos e Utilização em Saúde) e a Agency for Healthcare Research and Quality – AHRQ (Agência para Pesquisa e Qualidade em Saúde) estimaram que, em 2013, o custo hospitalar anual com pacientes com sepse no país foi de US\$ 24 bilhões.

Dada sua complexidade, a sepse pode ser difícil de diagnosticar; o diagnóstico precoce é crucial, conforme demonstrado em um estudo abrangente de 2006, cujos resultados revelaram que “cada hora de atraso na administração de antimicrobianos, dentro das primeiras seis horas após o início da hipotensão, estava associada a uma redução média de sobrevivência de 7,6%” (Kumar *et al.*, 2006). Assim, um importante princípio do cuidado da sepse é a identificação rápida e o tratamento imediato com antibióticos, por exemplo. Contudo, não existe nenhum sistema clinicamente validado que forneça uma previsão exata e em tempo real do início da sepse. De modo ideal, esse sistema também deve ser aprovado pelas agências reguladoras relevantes para garantir a segurança do paciente.


O objetivo do programa Artificial Intelligence Sepsis Expert – AISE (Inteligência Artificial Especialista em Sepse) (Nemati *et al.*, 2018) foi possibilitar o reconhecimento precoce de sepse em pacientes adultos na UTI. Especificamente, o algoritmo foi treinado em 31 mil pacientes da UTI da Universidade de Emory e validado com 52 mil pacientes do MIMIC-III, uma base de dados de cuidados críticos de livre acesso desenvolvida pelo Laboratório de Fisiologia Computacional do MIT (Johnson *et al.*, 2016b). O programa AISE foi desenvolvido a partir de rótulos de sepse derivados do protocolo do Terceiro Consenso Internacional de Definições sobre Sepse e Choque Séptico (Sepsis-3) (Seymour *et al.*, 2016). A equipe de pesquisa concluiu que

a ferramenta era capaz de prever a sepse com quatro a seis horas de antecedência (área sob a curva ROC – 95%; intervalo de confiança 0,85-0,88). Por causa da complexidade do cuidado crítico, incluindo os fluxos de dados longitudinais e altamente dimensionais e a rápida deterioração da condição de pacientes, o AISE foi projetado para produzir escores de risco, de hora em hora, que pudessem ser interpretados por equipes clínicas. Ademais, para aumentar a probabilidade da ampla adoção clínica, o sistema teve de ser projetado para ser generalizável, portátil e garantir a privacidade dos pacientes cujos dados fossem usados para treinamento e avaliações do modelo, assim como durante a implementação do sistema em tempo real.

NECESSIDADE DE INTERPRETABILIDADE

Como citado anteriormente, o sistema AISE foi implementado em um contexto produtivo de processamento de sinais vitais de alta resolução e medidas laboratoriais em tempo real, visando produzir escores de previsão e alertar profissionais de saúde sobre a iminência do desenvolvimento de um quadro séptico em pacientes, com antecedência entre quatro e seis horas. De forma geral, médicos não costumam aceitar uma recomendação realizada por computadores, a não ser que haja uma evidente base clínica para essa assinalação. Além disso, normas recentes, tais como o “direito à explicação”, determinado pelo Regulamento Geral sobre a Proteção de Dados da União Europeia (do inglês, *General Data Protection Regulation* – GDPR) (Goodman & Flaxman, 2017), restringem a aplicação de sistemas de tomada de decisão automatizados em cenários nos quais essas decisões tenham efeitos significativos nos usuários finais. Portanto, a equipe do AISE se concentrou em uma classe interpretável de modelos de IA, por meio da qual é possível realizar a análise das variáveis que mais foram relevantes no cálculo de escore de risco de um paciente específico. Isso foi possível ao considerar a métrica conhecida como “escore de relevância”, que mede a contribuição de cada característica para o escore de risco. Na Figura 1, há uma representação que ilustra as previsões do modelo AISE e os principais fatores conexos que contribuem para os escores de risco (Painel C). Essa noção da interpretabilidade foi ainda incorporada por meio de uma interface de usuário (IU) voltada ao profissional clínico (Figura 3). Cada paciente é representado por um cartão, que contém o número do quarto do paciente na parte de cima, o escore de risco de sepse e uma seta direcional com a magnitude da mudança (por exemplo, delta) de escore de risco de sepse ao longo das últimas horas. Ademais, os três fatores principais que contribuem para os escores de risco são apresentados na parte de trás, que é exibida ao clicar uma vez no cartão.

FIGURA 1

EXEMPLO DO ALGORITMO EM AÇÃO

FONTE: ELABORAÇÃO PRÓPRIA.


Nota: O Escore de Avaliação Sequencial de Falência de Órgãos (SOFA) – calculado a cada hora –, critérios do protocolo Sepsis-3 para sepse (Seymour et al., 2016) e o escore AISE estão visíveis para um dado paciente no Painel (A). Sinais vitais habitualmente registrados a cada hora estão apresentados no Painel (B). As características mais importantes contribuem para o escore AISE (para uma apresentação mais clara, apenas alguns marcos temporais são apresentados). Curiosamente, por volta das 16 horas do dia 20 de dezembro, cerca de oito horas antes de qualquer mudança no escore SOFA, o escore de sepse para o paciente começa a aumentar. Os principais fatores contribuintes (Painel C) são ligeiras alterações na frequência cardíaca (FC), frequência respiratória (RESP) e temperatura (TEMP), considerando que o paciente passou por uma cirurgia nas últimas 12 horas, com uma lesão contaminada, e estava sob ventilação mecânica. Perto de meia-noite do dia 21 de dezembro, outros fatores, como a entropia multiescala para sinais de variabilidade cardíaca (VFC1), o Glasgow Coma Scale (GCS) e o lactato apresentaram mudanças anormais. Cinco horas depois, o paciente demonstrou a definição Sepsis-3 de sepse. ABX: antibiótico, CultPos/Neg: Cultura positiva/negativa, O2Sat: Saturação de oxigênio.

NECESSIDADE DE GENERALIZAÇÃO

Um problema fundamental em muitos AM existentes e dos escores de risco com análises preditivas é sua falta de generalização entre instituições e a diminuição de desempenho dentro da mesma instituição ao longo do tempo (Kelly, Karthikesalingam, Suleyman, Corrado, & King, 2019). Essa generalização limitada se deve a vários fatores, incluindo diferenças nas populações locais, sistemas de RES, definições de códigos, testes e exames laboratoriais, assim como variações de práticas clínicas e administrativas. Em um estudo recente que visava detectar radiografias anormais do peito, a especificidade de um modelo de AM em um grau de sensibilidade fixa variou consideravelmente, de 0,566 a 1, entre cinco bases de dados independentes (Hwang *et al.*, 2019; Zech *et al.*, 2018). De forma similar, a maioria dos modelos clínicos de AM e de análise preditivas já publicados são baseados em dados de um único hospital (Futoma, Hariharan, & Heller, 2017; Henry, Hager, Pronovost, & Saria, 2015) ou de vários hospitais que compõem o mesmo sistema de saúde (Josef, Ramnath, Malhotra, & Nemati, 2019), nos quais os processos de cuidado são, em grande parte, padronizados. Apesar de menos comuns, modelos clínicos de AM que foram validados em diferentes sistemas de saúde às vezes tiveram que ser retreinados desde o começo a cada nova coorte de pacientes (Nemati *et al.*, 2018; Oh *et al.*, 2018), ou, quando aplicados sem modificações, tenderam a exibir uma diminuição significativa de seu desempenho (Bennett *et al.*, 2019).

Durante a avaliação externa, o modelo AISE previamente concebido a partir dos dados únicos da coorte de desenvolvimento foi refinado com o subgrupo de treinamento no local de validação, usando 20 iterações do gradiente descendente do algoritmo. O modelo AISE foi, então, avaliado no grupo de teste da coorte de validação. O objetivo da etapa de avaliação externa foi mostrar que o modelo poderia ser personalizado para as características da população local e ainda fornecer previsões precisas. Essa abordagem entra no marco conceitual de “aprendizado por transferência” na literatura do AM e tem conseguido melhorar o desempenho preditivo em comparação com o modelo treinado desde o começo a partir das coortes externas, especialmente quando há apenas dados limitados disponíveis para o treinamento (Deo, 2015). Nesse marco teórico, o conhecimento obtido ao resolver um problema de classificação na coorte de desenvolvimento é armazenado nos pesos da rede neural e encaminhado à próxima coorte-alvo (Figura 2). O aprendizado de um classificador preciso e generalizável na coorte-alvo pode ser alcançado usando menos dados de treinamento. Essa abordagem já foi usada para fazer o ajuste fino de um modelo de rede neural para detectar a retinopatia diabética em retinografias (Gulshan *et al.*, 2016).


FIGURA 2

DIAGRAMA ESQUEMÁTICO DO APRENDIZADO POR TRANFERÊNCIA

FONTE: ELABORAÇÃO PRÓPRIA.

Nota: O diagrama da Figura 2 apresenta: (1) Uma rede neural de modelo preditivo (como o AISE) é inicializada com pesos aleatórios e é treinada usando dados do local de desenvolvimento; (2) Começando com o modelo pré-treinado do local de desenvolvimento, os pesos do modelo são aperfeiçoados (ou retreinados) usando uma quantidade relativamente pequena de dados de treinamento do local de desenvolvimento, antes da avaliação, usando um conjunto de teste da coorte de validação.

FIGURA 3

FLUXOGRAMA DO SOFTWARE DE PREVISÃO DE SEPSE

FONTE: ELABORAÇÃO PRÓPRIA.

Nota: Os padrões *Fast Healthcare Interoperability Resources* – FHIR (Recursos Rápidos de Interoperabilidade em Saúde) e Health Level 7 (HL7) garantem um sistema interoperável. A abordagem de organização em *containers* (por meio de tecnologia Docker) aumenta a portabilidade e fornece um desenho modular que possibilita que microsserviços individuais (por exemplo, serviços de bases de dados locais ou de análise preditiva) se comuniquem por meio de chamadas de interface de programação de aplicação (API). Cada microsserviço rastreia todas as chamadas e respostas API que entram e saem e produzem registros de eventos para a gestão de qualidade e objetivos em cumprimento com a Lei de Portabilidade e Responsabilidade de Seguros de Saúde (HIPPA) dos Estados Unidos. A interface de usuário (IU) exibe um *ranking* de pacientes de acordo com seu risco de sepse (no formato de pequenos cartões) e permite que a equipe clínica interaja com o sistema.

NECESSIDADE DE INTEROPERABILIDADE E PORTABILIDADE

Em complemento à questão da generalização dos modelos do AM clínicos, há a exigência da padronização e acesso aos dados e a capacidade de introduzir, de forma integrada, um fluxograma de *software* com base em AM em uma nova instituição para a implementação. A Figura 3 ilustra como o AISE cumpre esses requisitos ao utilizar padrões de dados e protocolos de troca, como o padrão do marco de referência Recursos Rápidos de Interoperabilidade em Saúde (FHIR) do Health Level (HL7®) (Braunstein, 2018) e a containerização para portabilidade (Saltz *et al.*, 2017). O FHIR define uma coleção de normas tanto para o armazenamento de dados clínicos (ou seja, recursos FHIR) como para um conjunto de protocolos de API *REpresentational State Transfer* (REST) para a troca desses recursos. O uso dos microsserviços containerizados elimina a necessidade de instalar diferentes aplicações e suas dependências associadas a máquinas *hosts* nos diferentes locais de implementação. Isso também permite que o sistema AISE aproveite a escalabilidade e a tolerância a falhas inerentes a aplicações containerizadas (Sirin Software, 2018; Bernstein, 2014).

NECESSIDADE DE INTEGRAÇÃO DE DADOS MULTIMODAL

Algumas informações, de forma geral, são registradas apenas dentro dos dados narrativos (como anotações clínicas e laudos de radiologia) de sistemas de RES. Esses dados podem ser críticos para o AM clínico, apesar de não estarem diretamente disponíveis para a parcela estruturada dos dados. A Fração de Ejeção (FE) é um preditor importante de doenças cardiovasculares, mas ela pode ser registrada em laudos narrativos de um ecocardiograma. Portanto, técnicas de processamento de linguagem natural (PLN) clínico podem ser usadas para extrair covariantes como a FE (Garvin *et al.*, 2012; Patterson *et al.*, 2017) a fim de aumentar a capacidade preditiva dos métodos do AM clínicos. O PLN clínico pode ser baseado em regras (ou seja, na extração desses valores usando regras predefinidas por especialistas), baseado no AM (ou seja, no treinamento de um modelo usando textos clínicos anotados por especialistas), ou uma combinação das duas abordagens. Exemplos de sistemas de PLN clínico incluem MetaMap (Aronson, 2001), cTAKES (Savova *et al.*, 2010) e CLAMP (Soysal *et al.*, 2018). Ademais, os resultados de extração desses sistemas de PLN clínicos podem ser combinados para aprimorar o desempenho da extração (Kuo *et al.*, 2016).

NECESSIDADE DE PRIVACIDADE E SEGURANÇA DE DADOS

Essencial para a análise de qualquer dado relativo a seres humanos é a exigência de privacidade do paciente e segurança de dados, que, nos Estados Unidos, é pautada pela Lei de Portabilidade e Responsabilidade de Seguros de Saúde (HIPAA) e a política federal para a proteção de seres humanos em pesquisa, ou o *Common Rule* (Annas, 2003) e, na União Europeia, pelo Regulamento Geral sobre a Proteção de Dados (GDPR) (Voigt & von demme Bussche, 2017). Essas normas e suas contrapartes respectivas em diferentes países são essenciais para o tratamento confidencial de informações protegidas de saúde (PHI, na sigla em inglês para *Protected Health Information*) e protegendo sujeitos da pesquisa biomédica (Ohno-Machado, 2018b). Ao mesmo tempo que é altamente desejável o uso de código livre para algoritmos, *software* e dados na busca da garantia da reprodutibilidade e da generalização científicas, a natureza privada dos dados proíbe essa abordagem quando se trata de PHI.

A plataforma AISE aplica medidas de segurança durante sua implementação ao restringir acessos não autorizados a dados sensíveis e a APIs, e ao garantir que políticas de acesso e mecanismos de autenticação adequados sejam adotados. A API permite a definição de pontos únicos de acesso (por meio de portas predeterminados) e restringe o acesso a microserviços específicos. Essas políticas de acesso são definidas com antecedência, e registros de acesso/auditoria são gerados para garantir o cumprimento de políticas predefinidas. Além disso, essa abordagem minimiza o potencial de ataques de *denial of service*, ou DoS (negação de serviço) ao ignorar pedidos de serviço de fontes desconhecidas.


Tendências emergentes: um exemplo do uso de tecnologia *blockchain*

A tecnologia original de *blockchain* de bitcoin foi desenvolvida para criptomoeda, mas foi usada em várias outras aplicações, incluindo na assistência à saúde (Kuo, Kim, & Ohno-Machado, 2017). Várias plataformas novas foram desenvolvidas na última década e algumas já foram testadas em aplicações clínicas (Kuo, Zavaleta Rojas, & Ohno-Machado, 2019). Sua aplicação se torna especialmente atrativa quando um grupo de instituições estão colaborando entre si e, apesar de possuírem confiança mútua, decidem verificar as ações umas das outras. O *blockchain* pode ter um papel na gestão de dados e modelos. Como indicado na seção anterior, existem muitos requisitos para um sistema de IA ser bem-sucedido. O *blockchain* não é uma panaceia para a gestão da complexa rede de dados e transações de modelo necessários para que a IA seja viável em ambientes clínicos; contudo, pode servir como uma ferramenta valiosa nos casos em que seja importante ter fontes confiáveis de dados, metadados e modelos em uma rede de instituições colaboradoras. As transações que ocorrem pela rede precisam ser fáceis de fiscalizar e extremamente difíceis de ser adulteradas.

Tradicionalmente, a segurança dos dados nos estabelecimentos de saúde é garantida por meio do uso de *firewalls* (sistemas de acesso restrito) e normas rígidas relativas à amplitude e quantidade de dados de paciente que podem ser arquivados. Mais recentemente, protocolos de criptografia foram aplicados. Contudo, para viabilizar o treinamento de modelos e a avaliação em várias instituições, novos paradigmas de segurança e AM foram desenvolvidos. Em particular, o aprendizado distribuído (Wu, Jiang, Kim, & Ohno-Machado, 2019; Wang *et al.*, 2013) e a tecnologia *blockchain* (Nakamoto, 2008) foram combinados para proteger a privacidade do AM clínico, ao mesmo tempo que reduz riscos à segurança (Figura 4). O aprendizado distribuído dissemina modelos do AM (ou seja, parâmetros agregados), em vez de dados PHI em nível do paciente, para outras instituições que estão colaborando para desenvolver modelos do AM generalizáveis. Todavia, métodos convencionais de aprendizado distribuídos exigem um servidor central para integrar os modelos do AM; porém, um intermediário central pode representar ponto único de falha (ou seja, o processo inteiro do AM falha se o servidor central não estiver funcionando). Para mitigar esse risco de segurança, métodos de modelagem baseados em *blockchain* que protegem privacidade (Kuo, Gabriel, Cidambi, & Ohno-Machado, 2020) adotam uma topologia de rede *peer-to-peer* (ou ponto-a-ponto), que promove as vantagens já conhecidas do uso do *blockchain*, como a imutabilidade, transparência e certeza da proveniência dos dados (Kuo *et al.*, 2017).

Além disso, uma característica importante das mais recentes tecnologias *blockchain* é a possibilidade da codificação de “contratos inteligentes” ou *smart contracts* (Buterin, 2019). Esses contratos são extensões do código da tecnologia original *blockchain* 1.0, que registrava transações, mas não registrava as “regras” ou os algoritmos que permitiam essas transações sob circunstâncias específicas (ou seja, contratos entre duas partes). A tecnologia *blockchain* 2.0 permite embutir códigos na cadeia de blocos para gerir transações, fazendo com que não apenas os dados, mas também o código, esteja incluso na cadeia de forma imutável. A propriedade da imutabilidade da tecnologia *blockchain* justifica sua aplicação como um registro distribuído que fornece aos usuários controle sobre seus próprios dados, como no caso da gestão de consentimento quanto ao uso de dados para estudos genéticos entre instituições ou para registros eletrônicos de saúde (Yu, Sun, Wu, & Kuo, 2020) e das cadeias de fornecimento para averiguar a proveniência dos dados (Mackey *et al.*, 2019), etc.

FIGURA 4
AM CLÍNICO QUE PROTEGE A PRIVACIDADE



FONTE: KUO & OHNO-MACHADO, 2018.

Nota: A Figura 4 apresenta: (A) Uma abordagem convencional que apenas transfere modelos, não dados de PHI. Para integrar os modelos do AM de cada local, essa abordagem exige um servidor central, que pode apresentar um ponto único de falha (ou seja, todo o processo do AM é interrompido se esse servidor falhar). (B) Uma solução de *blockchain* que é distribuída e, portanto, não apresenta nenhum ponto único de falha. Ademais, o uso do *blockchain* fornece registros imutáveis, transparentes e com fontes verificáveis dos modelos de AM.

Conclusão

O uso de IA na medicina clínica foi proposto décadas atrás, mas só foi viabilizado quando dados suficientes, métodos aprimorados e tecnologias eficientes tornaram-se disponíveis em grande escala. Agora, há um número crescente de aplicações na pesquisa biomédica e em saúde que utilizam várias tecnologias de IA. É possível deduzir que a IA tornar-se-á parte integral de muitas aplicações clínicas e que seu uso amplo e integrado acelerará o avanço de soluções de saúde, assim como de descobertas biomédicas. Contudo, ainda, há muitas áreas de possível melhoria para ajudar os clínicos a fazerem uso pleno dos dados de sistemas de RES com o intuito de otimizarem a prestação de cuidados. Neste artigo, foi colocado um exemplo no qual um alerta para sepse pode ser emitido várias horas antes do diagnóstico “oficial”, assim, gerando possíveis avanços logo no início do tratamento, o que pode resultar em diferenças significativas nos resultados dos pacientes. Também foi apresentado que, para melhor aproveitar e concretizar o poder de *Big Data* clínico e da IA visando aumentar a qualidade do cuidado do paciente, é preciso superar vários desafios relativos à transparência, generalização, portabilidade, acessibilidade e privacidade do paciente. Foi demonstrado como o uso crescente da tecnologia *blockchain* pode ajudar a contornar esses problemas. Diante disso, é possível acreditar que esses desafios serão resolvidos por meio de uma combinação entre ciência, tecnologia e políticas públicas, e que a IA será perfeitamente integrada em muitas atividades clínicas em um futuro próximo.

Agradecimentos

Os autores Shamim Nemati, Supreeth P. Shashikumar e Fatemeh Amrollahi são financiados pelo National Institutes of Health (NIH) K01ES025445, National Science Foundation (NSF) 1822378, Biomedical Advanced Research and Development Authority HHSO100201900015C, e a Fundação Gordon and Betty Moore GBMF9052. Tsung-Ting Kuo é financiado pelo NIH R00HG009680, R01HL136835, R01GM118609 e U01EB023685; Bolsa de Pesquisa Acadêmica do Senado (UCSD Academic Senate Research Grant RG084150). Lucila Ohno-Machado é financiada pelo NIH R01HL136835, R01GM118609, U01EB023685, OT2OD026552 e R01HG011066; NSF OIA-1937136. O conteúdo é de inteira responsabilidade dos autores e não expressa, necessariamente, as visões oficiais das agências financiadoras, as quais não participaram da delimitação do estudo, da coleta de dados e da análise de dados, nem da decisão de publicar ou da preparação do manuscrito.

Referências

- Annas, G. J. (2003). HIPAA regulations — A new era of medical-record privacy? *The New England Journal of Medicine*, 348(15), 1486–1490.
- Aronson, A. R. (2001). Effective mapping of biomedical text to the UMLS Metathesaurus: The MetaMap program. *Proceedings of the AMIA Annual Symposium*, 17–21.
- Bates, D. W., Saria, S., Ohno-Machado, L., Shah, A., & Escobar, G. (2014). Big data in health care: Using analytics to identify and manage high-risk and high-cost patients. *Health Affairs*, 33(7), 1123–1131.
- Bennett, T., Russell, S., King, J., Schilling, L., Voong, C., Rogers, N., . . . Ghosh, D. (2019). *Accuracy of the Epic Sepsis Prediction Model in a regional health system*. ArXiv190207276 Cs Stat. Recuperado em 20 agosto, 2020, de <http://arxiv.org/abs/1902.07276>
- Bernstein, D. (2014). Containers and cloud: From LXC to Docker to Kubernetes. *IEEE Cloud Computing*, 1(3), 81–84.
- Braunstein, M. L. (2018). Healthcare in the age of interoperability: The promise of fast healthcare interoperability resources. *IEEE Pulse*, 9(6), 24–27.
- Buterin, V. (2019). A next generation smart contract & decentralized application platform. *Ethereum White Paper*.
- Cho, I., Boo, E-H., Chung, E., Bates, D. W., & Dykes, P. (2019). Novel approach to inpatient fall risk prediction and its cross-site validation using time-variant data. *Journal of Medical Internet Research*, 21(2), e11505.
- Churpek, M. M., Yuen, T. C., Winslow, C., Meltzer, D. O., Kattan, M. W., & Edelson, D.P. (2016). Multicenter comparison of machine learning methods and conventional regression for predicting clinical deterioration on the wards. *Critical Care Medicine*, 44(2), 368–74.
- Connell, A., Montgomery, H., Martin, P., Nightingale, C., Sadeghi-Alavijeh, O., King, D., . . . Raine, R. (2019). Evaluation of a digitally-enabled care pathway for acute kidney injury management in hospital emergency admissions. *NPJ Digital Medicine*, 2(1), 1–9.
- Deo, R. C. (2015). Machine learning in medicine. *Circulation*, 132(20), 1920–1930.
- Dilsizian, S. E., & Siegel, E. L. (2014). Artificial intelligence in medicine and cardiac imaging: Harnessing big data and advanced computing to provide personalized medical diagnosis and treatment. *Current Cardiology Reports*, 16(1), 441.
- Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristom, M., Chou, K., . . . Dean, J. (2019). A guide to deep learning in healthcare. *Nature Medicine*, 25(1), 24–29.
- Futoma, J., Hariharan, S., & Heller, K. (2017). Learning to detect sepsis with a multitask gaussian process RNN classifier. *Proceedings of the International Conference on Machine Learning*, Sydney, Australia, 34 (JMLR.org, p. 1174–1182).
- Garvin, J. H., DuVall, S. L., South, B. R., Bray, B. E., Bolton, D., Heavirland, J., . . . Goldstein, M. K. (2012). Automated extraction of ejection fraction for quality measurement using regular expressions in Unstructured Information Management Architecture (UIMA) for heart failure. *Journal of the American Medical Informatics Association: JAMIA*, 19(5), 859–866.

- Giannini, H. M., Ginestra, J. C., Chivers, C., Draugelis, M., Hanish, A., Schweickert, W. D., . . . Umscheid, C. (2019). A machine learning algorithm to predict severe sepsis and septic shock: Development, implementation, and impact on clinical practice. *Critical Care Medicine*, 47(11), 1485–92.
- Goodman, B., & Flaxman, S. (2017). European Union regulations on algorithmic decision-making and a “right to explanation.” *AI Magazine*, 38(3), 50–57.
- Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., . . . Webster, D. R. (2016). Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA*, 316(22), 2402–2410.
- Hao, S., Wang, Y., Jin, B., Shin, A. Y., Zhu, C., Huang, M., . . . Ling, X. B. (2015). Development, validation and deployment of a real time 30 day hospital readmission risk assessment tool in the Maine healthcare information exchange. *PloS One*, 10(10), e0140271.
- He, J., Baxter, S. L., Xu, J., Xu, J., Zhou, X., & Zhang, K. (2019). The practical implementation of artificial intelligence technologies in medicine. *Nature Medicine*, 25(1), 30–36.
- Henry, K. E., Hager, D. N., Pronovost, P. J., & Saria, S. (2015). A targeted real-time early warning score (TREWScore) for septic shock. *Science Translational Medicine*, 7(299), 299ra122.
- Hwang, E. J., Park, S., Jin, K.-N., Kim, J. I., Choi, S. Y., Lee, J. H., . . . Park, C. M. (2019). Development and validation of a deep learning-based automated detection algorithm for major thoracic diseases on chest radiographs. *JAMA Network Open*, 2(3), 191095.
- Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., . . . Wang, Y. (2017). Artificial intelligence in healthcare: Past, present and future. *Stroke and Vascular Neurology*, 2(4), 230–243.
- Johnson, A. E. W., Ghassemi, M. M., Nemati, S., Niehaus, K. E., Clifton, D. A., & Clifford, G. D. (2016a). Machine learning and decision support in critical care. *Proceedings of the IEEE, Institute of Electrical and Electronics Engineers*, 104(2), 444–466.
- Johnson, A. E. W., Pollard, T. J., Shen, L., Li-wei, H. L., Feng, M., Ghassemi, M., . . . Mark, R. G. (2016b). MIMIC-III, a freely accessible critical care database. *Scientific Data*, 3, 160035.
- Josef, C. S., Ramnath, V., Malhotra, A., & Nemati, S. (2019). Performance comparison of unit specific and generalizable sepsis prediction models across intensive care units. *SHOCK*, 85–86.
- Kelly, C. J., Karthikesalingam, A., Suleyman, M., Corrado, G., & King, D. (2019). Key challenges for delivering clinical impact with artificial intelligence. *BMC Medicine*, 17(1), 195.
- Kumar, A., Roberts, D., Wood, K. E., Light, B., Parrillo, J. E., Sharma, S., . . . Cheang, M. (2006). Duration of hypotension before initiation of effective antimicrobial therapy is the critical determinant of survival in human septic shock. *Critical Care Medicine*, 34(6), 1589–1596.
- Kuo, T.-T., & Ohno-Machado, L. (2018). *ModelChain: Decentralized privacy-preserving healthcare predictive modeling framework on private blockchain networks*. ArXiv180201746 Cs. Recuperado em 20 agosto, 2020, de <http://arxiv.org/abs/1802.01746>

- Kuo T-T., Kim, H-E., & Ohno-Machado, L. (2017). Blockchain distributed ledger technologies for biomedical and health care applications. *Journal of the American Medical Informatics Association: JAMIA*, 24(6), 1211–1220.
- Kuo, T-T., Rao, P., Maehara, C., Doan, S., Chaparro, J. D., Day, M. E., . . . Hsu, C. N. (2016). Ensembles of NLP tools for data element extraction from clinical notes. *Proceedings of the Annual AMIA Symposium*, 1880-1889. Recuperado em 20 agosto, 2020, de <https://www.ncbi.nlm.nih.gov/pubmed/28269947>
- Kuo, T-T., Zavaleta, Rohas, H., & Ohno-Machado, L. (2019). Comparison of Blockchain platforms: A systematic review and healthcare examples. *Journal of the American Medical Informatics Association: JAMIA*, 26(5), 462–478.
- Kuo, T. T., Gabriel, R. A., Cidambi, K. R., & Ohno-Machado, L. (2020). EXpectation Propagation LOGistic REGression on permissioned Blockchain (ExplorerChain): Decentralized online healthcare/genomics predictive model learning. *Journal of the American Medical Informatics Association: JAMIA*, 27(5), 747-756.
- Levin, S., Toerper, M., Hamrock, E., Hinson, J. S., Barnes, S., Gardner, H., . . . Kelen, G. (2018). Machine-learning-based electronic triage more accurately differentiates patients with respect to clinical outcomes compared with the emergency severity index. *Annals of Emergency Medicine*, 71(5), 565–574.
- Luo, J., Wu, M., Gopukumar, D., & Zhao, Y. (2016). Big data application in biomedical research and health care: A literature review. *Biomed Informatics Insights*, 8, 1–10.
- Mackey, T. K., Kuo, T-T., Gummadi, B., Clauson, K. A., Church, G., Grishin, D., . . . Palombini, M. (2019). ‘Fit-for-purpose?’ – challenges and opportunities for applications of Blockchain technology in the future of healthcare. *BMC Medicine*, 17(1), 68.
- Miller, R. A., McNeil, M. A., Challinor, S. M., Masarie, F. E., & Myers, J. D. (1986). The INTERNIST-1/QUICK MEDICAL REFERENCE project—status report. *The Western Journal of Medicine*, 145(6), 816–22.
- Min, X., Yu, B., & Wang, F. (2019). Predictive modeling of the hospital readmission risk from patients’ claims data using machine learning: A case study on COPD. *Scientific Reports*, 9(1), 362.
- Nakamoto S. (2008). *Bitcoin: A peer-to-peer electronic cash system*. Satoshi Nakamoto Institute.
- Nemati, S., Holder, A., Razmi, F., Stanley, M. D., Clifford, G. D., & Buchman, T. G. (2018). An interpretable machine learning model for accurate prediction of sepsis in the ICU. *Critical Care Medicine*, 46(4), 547–53.
- Oh, J., Makar, M., Fusco, C., McCaffrey, R., Rao, K., Ryan, E. E., . . . Wiens, J. (2018). A generalizable, data-driven approach to predict daily risk of clostridium difficile infection at two large academic health centers. *Infection Control and Hospital Epidemiology*, 39(4), 425–433.
- Ohno-Machado, L. (2018a). Data science and artificial intelligence to improve clinical practice and research. *Journal of the American Medical Informatics Association: JAMIA*, 25(10), 1273.
- Ohno-Machado, L. (2018b). Sharing data from electronic health records within, across, and beyond healthcare institutions: Current trends and perspectives. *Journal of the American Medical Informatics Association: JAMIA*, 25(9), 1113.

- Olsen, L., Aisner, C., & McGinnis, J. M. (Eds.). (2007). *The learning healthcare system*. Workshop Summary of Institute of Medicine Roundtable on Evidence-Based Medicine. Washington, DC: National Academies Press.
- Patel, V. L., Shortliffe, E. H., Stefanelli, M., Szolovits, P., Berthold, M.R., Bellazzi, R., & Hanna, A. (2009). The coming of age of artificial intelligence in medicine. *Artificial Intelligence in Medicine*, 46(1), 5–17.
- Patterson, O. V., Freiberg, M. S., Skanderson, M. J., Fodeh, S., Brandt, C. A., & DuVall, S. L. (2017). Unlocking echocardiogram measurements for heart disease research through natural language processing. *BMC Cardiovascular Disorders*, 17(1), 151. Recuperado em 20 agosto, 2020, de <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5469017/>
- Rajkomar, A., Oren, E., Chen, K., Dai, A. M., Hajaj, N., Hardt, M., . . . Dean, J. (2018). Scalable and accurate deep learning with electronic health records. *NPJ Digital Medicine*, 1(1), 18.
- Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., & Yang, G. Z. (2017). Deep learning for health informatics. *IEEE Journal of Biomedical and Health Informatic*, 21(1), 4–21.
- Saltz, J., Sharma, A., Iyer, G., Bremer, E., Wang, F., Jasnowski, A., . . . Kurc, T. (2017). A containerized software system for generation, management, and exploration of features from whole slide tissue images. *Cancer Research*, 77(21), e79–e82.
- Savova, G. K., Masanz, J. J., Ogren, P. V., Zheng, J., Sohn, S., Kipper-Schuler, K. C., & Chute, C. G. (2010). Mayo clinical Text Analysis and Knowledge Extraction System (cTAKES): Architecture, component evaluation and applications. *Journal of the American Medical Informatics Association: JAMIA*, 17(5), 507–513.
- Sendak, M. P., D'Arcy, J., Kashyab, S., Gao, M., Nichols, M., Corey, K., . . . Balu, S. (2020). A path for translation of machine learning products into healthcare delivery. *EMJ Innov*. Recuperado em 20 agosto, 2020, de <https://www.emjreviews.com/innovations/article/a-path-for-translation-of-machine-learning-products-into-healthcare-delivery/>
- Seymour, C. W., Liu, V. X., Iwashyna, T. J., Brunkhorst, F. M., Rea, T. D., Scherag, A., . . . Angus, D. C. (2016). Assessment of clinical criteria for sepsis: For the third international consensus definitions for sepsis and septic shock (sepsis-3). *JAMA*, 315(8), 762–774.
- Shashikumar, S. P., Josef, C., Sharma, A., & Nemati, S. (2019). *DeepAISE—an end-to-end development and deployment of a recurrent neural survival model for early prediction of sepsis*. ArXiv Prepr ArXiv190804759.
- Shortliffe E.H., & Fagan L.M. (1985). Artificial Intelligence: the expert systems approach to medical consultation. In P. M. Osswald (Eds.). *Computers in critical care and pulmonary medicine*. Berlin: Springer.
- Sirin Software. (2018). *Kubernetes - a new advanced container management power*. Recuperado em 20 agosto, 2020, de <https://sirinsoftware.com/blog/kubernetes-a-new-advanced-container-management-power/>
- Soysal, E., Wang, J., Jiang, M., Wu, Y., Pakhomov, S, Liu, H., . . . Xu, H. (2018). CLAMP - a toolkit for efficiently building customized clinical natural language processing pipelines. *Journal of the American Medical Informatics Association: JAMIA*, 25(3), 331–336.

- Tangri, N., Stevens, L. A., Griffith, J., Tighiouart, H., Djurdjev, O., Naimark, D., . . . Levey, A. (2011). A predictive model for progression of chronic kidney disease to kidney failure. *JAMA*, 305(15), 1553–1559.
- Topol, E. J. (2019). High-performance medicine: The convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44–56.
- Ugalmugle, S., & Devgire, A. (2019). Global digital healthcare market size to exceed \$504.4 Bn by 2025. *Global Market Insights, Inc.* Recuperado em 20 agosto, 2020, de <https://www.gminsights.com/pressrelease/digital-health-market>
- Voigt, P., & von dem Bussche, A. (2017). Scope of application of the GDPR. In P. Voigt, & A. von dem Bussche (Eds.). *The EU General Data Protection Regulation (GDPR): A practical guide* (pp. 9–30). Cham, Switzerland: Springer International Publishing.
- Wang, S., Jiang, X., Wu, Y., Cui, L., Cheng, S., & Ohno-Machado, L. (2013). EXpectation Propagation LOGistic REGression (EXPLORER): Distributed privacy-preserving online model learning. *Journal of Biomedical Informatics*, 46(3), 480–496.
- Wu, Y., Jiang, X., Kim, J., & Ohno-Machado, L. (2012). Grid Binary LOGistic REGression (GLORE): Building shared models without sharing data. *Journal of the American Medical Informatics Association: JAMIA* 19(5), 758–64.
- Yu, H., Sun, H., Wu, D., & Kuo T-T. (2020). Comparison of smart contract blockchains for healthcare applications. *Proceedings of the Annual AMIA Symposium*, 1266–1275.
- Zech, J. R., Badgeley, M. A., Liu, M., Costa, A. B., Titano, J. J., & Oermann, E. K. (2018). Variable generalization performance of a deep learning model to detect pneumonia in chest radiographs: A cross-sectional study. *PLoS Medicine*, 15(11), e1002683. Recuperado em 20 agosto, 2020, de <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6219764>

Aprendizado de máquina em medicina cardiovascular

Marco Antonio Gutierrez¹ e José Eduardo Krieger²

Natureza e complexidade de dados de saúde

A difusão da adoção do uso de Registro Eletrônico de Saúde (RES) em hospitais e clínicas em todo o mundo levou à criação de conjuntos de dados de pacientes que são muito volumosos, heterogêneos e que estão continuamente expandindo e incorporando novas variáveis.

Dados relacionados à assistência à saúde são complexos e apresentam inúmeros desafios computacionais. Essa complexidade é parcialmente inerente às condições de saúde, adicionada à heterogeneidade dessas condições. Neste contexto, as doenças cardiovasculares são consideradas um paradigma, uma vez que representam grande ônus para o sistema de saúde devido a sua prevalência e a fatores mais básicos, que envolvem uma interação complexa entre fatores genéticos e ambientais. Além disso, alguns desses fatores podem interagir com sistemas reguladores que mantêm uma influência prejudicial até décadas depois, quando então os sinais e sintomas das doenças se manifestam. A complexidade também é resultado da natureza irregular da coleta de informações dos pacientes e do tipo de variáveis coletadas em um dado momento. Estas últimas podem refletir um evento agudo relacionado à saúde e não um conjunto estruturado de variáveis para a gestão de saúde de um indivíduo em longo prazo. Além disso, a interpretação dessas medidas pode variar com o tempo (por exemplo, o valor aceitável dos níveis

¹ Pós-doutor em Processamento de Imagens Médicas pela Universidade de Utrecht, na Holanda (1996), doutor em Engenharia Elétrica pela Escola Politécnica da Universidade de São Paulo - USP (1995), graduado pela Escola de Engenharia da USP em São Carlos (1985). Professor livre-docente em Informática Médica pela Universidade Federal de São Paulo - UNIFESP (2008) e integra o Departamento de Cardiopneumologia da Faculdade de Medicina da USP, onde é professor assistente. É chefe do Serviço de Informática e do Laboratório de Informática Biomédica do Instituto do Coração (HC-FMUSP).

² Pós-doutor em Biologia Molecular na Harvard Medical School (1990) e na Stanford University School of Medicine, nos Estados Unidos (1992), doutor em Fisiologia pela Faculdade de Medicina de Wisconsin, também nos Estados Unidos (1988), graduado pela Faculdade de Medicina de Ribeirão Preto da USP (1984). Faz parte do Departamento de Cardiopneumologia da Faculdade de Medicina da USP, onde é professor titular de Medicina Molecular e chefe do Laboratório de Genética e Cardiologia Molecular do Instituto do Coração (HC-FMUSP).

de colesterol pode mudar de acordo com novas descobertas científicas) e o intervalo aceitável (bom, limítrofe, alto ou baixo) pode variar de acordo com o método usado (e, consequentemente, com o aprimoramento das técnicas). Por fim, há uma abundância de dados coletados e armazenados relacionados às visitas, incluindo diagnósticos, prescrições, exames laboratoriais, procedimentos de imagem, medicamentos e intervenções. Os tipos de dados biomédicos abrangem texto livre, dados estruturados e sinais multidimensionais, tais como eletrocardiograma (ECG), imagens 2D (raios-X), volumes 3D (como tomografia computadorizada ou ressonância magnética) e dados 4D (como aquisições de ressonância magnética temporal do coração 3D + tempo).

A revolução ômica

A decodificação do genoma humano em 2003 acrescentou uma nova dimensão para abordar o estudo de doenças. Ela foi seguida da criação de bases de dados de variantes genéticas humanas, como o projeto HapMap (Altshuler & Donnelly, 2005) e o projeto 1000 Genomas (The 1000 Genomes Project Consortium, 2012) que, juntamente com a evolução das tecnologias de genotipagem, permitiram o primeiro estudo de associação genômica ampla (GWAS) em doenças complexas. Na sequência de estudos, utilizando um número maior de indivíduos e meta-análise, em que dados de diferentes recursos são integrados usando atribuição de genótipos (Howie, Donnelly, & Marchini, 2009) com base em bancos de dados de variantes genéticas, foram identificadas milhares dessas variantes associadas a um ou mais traços complexos (Visscher *et al.*, 2017). No entanto, a maioria das variantes identificadas até agora fornece um pequeno efeito de risco e explica apenas uma pequena fração da variância fenotípica ou do agrupamento familiar, não respondendo à questão primordial relacionada à hereditariedade de doenças complexas (Teixeira, Pereira, & Krieger, 2018; Giri *et al.*, 2019; Evangelou *et al.*, 2017).

Em 2004, foi lançado o primeiro grande consórcio para identificar marcas epigenéticas em diferentes tecidos e tipos de células, denominado ENCODE (ENCODE Project Consortium, 2004). Mais de 10 anos depois, o consórcio Roadmap Epigenomics Mapping gerou a maior coleção até o momento de epigenomas humanos para células e tecidos primários (Kundaje *et al.*, 2015). Foi usada uma diversidade de ensaios, incluindo imunoprecipitação da cromatina (ChIP), digestão de DNA por DNaseI (DNase), tratamento com bissulfito, imunoprecipitação de DNA metilado (MeDIP), digestão por enzimas de restrição sensível à metilação (MSREs) e perfil de RNA, cada um seguido por um sequenciamento de curta duração massivamente paralelo. Os dados foram processados e disponibilizados em um repositório público para uso pela comunidade científica. Em 2017, foi publicado um novo esforço para melhorar o projeto Genotype-Tissue Expression (GTEx), denominado Enhancing GTEx (eGTEx) Project, que “combina a expressão gênica com medições moleculares intermediárias adicionais nos mesmos tecidos, de forma a fornecer um recurso para estudar como as diferenças genéticas são passadas através de fenótipos moleculares para impactar a saúde humana” (Stranger *et al.*, 2017). Todos esses bancos de dados públicos permitem a análise de múltiplas camadas para entender a complexidade molecular de doenças comuns.

Inteligência Artificial na integração de dados de saúde

Uma solução para superar as dificuldades para a extração de informações significativas que podem estar escondidas nos conjuntos volumosos e complexos de dados de saúde é o uso de técnicas de Inteligência Artificial ou aprendizado de máquina.

A pesquisa em aprendizado de máquina é marcada por ondas. A primeira, na década de 1960, trouxe a proposta do neurônio artificial e das primeiras arquiteturas de rede neural artificial (RNA), o Perceptron e o Adaline. Essas redes estavam limitadas a resolver problemas que envolviam classes linearmente separáveis, e os algoritmos de treinamento só se aplicavam a redes com uma única camada. A segunda onda, nos anos 1980, a partir da introdução do método de retropropagação para o treinamento de redes com camadas ocultas, proporcionou uma melhoria significativa na solução de problemas no reconhecimento de padrões em algumas áreas do conhecimento. Entretanto, as aplicações na área de Ciência da Saúde eram ainda muito limitadas. No final do século 20, a proposta de RNA para solução de problemas complexos, como a análise de imagens, exigiu um conjunto completo de novas arquiteturas, bem como maior poder computacional para permitir o treinamento de redes com maior número de camadas, ou camadas profundas. As redes neurais profundas, conhecidas como “aprendizagem profunda” ou *deep learning*, que surgiram no final da primeira década do século 21, constituem a terceira onda. Entre essas redes, as redes neurais convolucionais (CNN) são as que têm um maior número de aplicações. Eles introduziram uma mudança fundamental na arquitetura da RNA, que foi a importância das camadas de convolução. Em vez de multiplicar enormes matrizes de peso pela ativação das camadas anteriores, a CNN usa a convolução de filtros pequenos com um pequeno número dessas ativações. Essa mudança reduz significativamente a memória usada para armazenar os parâmetros da rede. Além disso, uma nova camada – a de amostragem – foi introduzida, inspirada pelo processamento do córtex visual de mamíferos. Ela fornece às redes a invariância para pequenas translações, rotações e, ocasionalmente, ruído aditivo em uma imagem. Finalmente, uma mudança fundamental com a terceira onda é que, ao contrário da geração anterior de ferramentas de aprendizado, a CNN não precisa de uma etapa anterior de extração de características. As camadas iniciais da arquitetura são agora responsáveis por essa tarefa. Do ponto de vista computacional, as unidades de processamento gráfico, conhecidas como GPU (do inglês, *graphics processing unit*), conferiram o poder computacional necessário à evolução tecnológica atual. A CNN foi considerada um dos dez maiores avanços tecnológicos do ano de 2013 (Hof, 2013).

Ao longo das três ondas mencionadas, observou-se um aumento significativo da profundidade das redes, ou do número de camadas e, conseqüentemente, do número de neurônios dessas redes. Além disso, para o treinamento supervisionado de arquiteturas cada vez mais profundas, é necessário dispor de bancos de dados rotulados e anotados com milhares de exemplos.

Até o momento, um dos principais focos desses estudos é a detecção e segmentação de estruturas de interesse em imagens médicas (Cireşan, Giusti, Gambardella, & Schmidhuber, 2013; Oliveira *et al.*, 2018; Tajbakhsh, Gurudu, & Liang, 2015; Tajbakhsh, Gotway, & Liang, 2015). Por outro lado, há um interesse crescente no processamento da linguagem natural em saúde por meio da aprendizagem profunda, uma vez que grande parte do conhecimento médico está contido em textos livres, que

estão registrados em narrativas do RES, como os existentes na anamnese, evolução, clínica resumo, entre outros.

A adoção crescente dos RES oferece uma oportunidade única para análise de dados secundários em saúde e, a partir desses bancos de dados, identificar os fenótipos do paciente que possam indicar uma determinada doença ou alertar que há risco de desenvolvimento de uma doença. Em um futuro muito próximo, a adoção da aprendizagem de máquina na área da saúde, especialmente na determinação automática dos fenótipos do paciente, pode ser uma ferramenta importante para apoiar a prática clínica, reduzindo o tempo de análise e avaliação do histórico do paciente e aumentando a precisão do diagnóstico (Gehrmann *et al.*, 2018).

Análise de imagens médicas

A avaliação de doenças baseada em imagens médicas depende muito da interpretação de imagens por especialistas humanos (radiologistas). Esse quadro mudou rapidamente nas últimas décadas, à medida que os métodos computacionais beneficiavam o processo de interpretação de imagens, fornecendo ferramentas poderosas para ajudar os médicos a obter diagnósticos mais precisos (Greenspan, Ginneken, & Summers, 2016; Litjens *et al.*, 2017; Shen, Wu, & Suk, 2017).

O processo diagnóstico a partir de imagens geralmente requer uma busca inicial por estruturas-alvo (segmentação), quantificação de parâmetros e métricas (como forma, tamanho, movimento e opacidade) para encontrar possíveis anormalidades ou busca por mudanças dos parâmetros ao longo do tempo, entre outros. O campo da análise computadorizada de imagens médicas vem abordando esses problemas desde a década de 1970. As técnicas de processamento, que inicialmente eram realizadas no nível do *pixel*, evoluíram rapidamente para modelagem matemática por sistemas baseados em regras (Greenspan *et al.*, 2016). Essas técnicas, embora possam ter funcionado muito bem para tarefas específicas, não são generalizáveis para uma gama ampla de aplicações. A introdução de técnicas de aprendizado de máquina tem alterado esse quadro, tornando-se uma ferramenta poderosa para facilitar a identificação de anormalidades e auxiliar o fluxo de trabalho do médico (Shen *et al.*, 2017).

A transição dos sistemas baseados em modelo para sistemas que aprendem com os dados foi gradual no início. No entanto, o número de trabalhos publicados na área vem aumentando exponencialmente desde 2015. Entre essas técnicas, o aprendizado profundo está emergindo como o estado da arte, levando a uma maior precisão e abrindo novas fronteiras na análise de imagens médicas (Greenspan *et al.*, 2016). Métodos de aprendizagem profunda têm sido utilizados para segmentação, detecção de objetos ou lesões, classificação, registro, rastreamento, entre outras aplicações. Atualmente, a aprendizagem profunda é aplicada mais às imagens médicas do que a qualquer outro tipo de dados de saúde (Wainberg, Merico, Delong, & Frey, 2018).

Apesar dos avanços na área, há muitos desafios a serem enfrentados. A falta de grandes conjuntos de dados de treinamento é frequentemente vista como um obstáculo importante, já que conjuntos de dados de treinamento pequenos podem levar a decisões imprecisas (Krittanawong, Zhang, Wang, Aydar, & Kitai, 2017).

Análise de sinais fisiológicos

Sinais fisiológicos são fontes de dados inestimáveis, que auxiliam na detecção, reabilitação e tratamento de doenças (Faust & Bairy, 2012). Os sinais vêm de sensores implantados ou colocados em contato com a pele (Wang & Shang, 2013). Por sua vez, a localização desses sensores determina as características do sinal fisiológico, cujas informações relevantes devem ser extraídas a fim de apoiar uma aplicação específica de saúde (Devasahayam, 2013).

Recentemente, arquiteturas de aprendizado profundo foram propostas para análise automática de sinais, levando em consideração todas as informações que um conjunto de dados de treinamento tem a oferecer. Como em outras aplicações de saúde, o objetivo principal do uso de métodos de aprendizagem profunda é criar uma boa representação de características e conhecimento a partir dos dados de entrada (Rahhal *et al.*, 2016). Aplicações descritas para sinais fisiológicos incluem: classificação dos estágios do sono a partir de dados de polissonografia (Långkvist, Karlsson, & Loutfi, 2012), predição de crises epiléticas de sinais do eletroencefalograma (EEG) (Mirowski, LeCun, Madhavan, & Kuzniecky, 2008), classificação automática de sinais de ECG (Mathews, Kambhamettu, & Barner, 2018; Rahhal *et al.*, 2016) e detecção de arritmias cardíacas (Isin & Ozdalili, 2017).

Análise de narrativas

As técnicas de processamento de linguagem natural (PLN) têm sido usadas para identificar, extrair e processar dados não estruturados de narrativas no RES e, assim, tirar proveito do grande potencial de informações clínicas nos registros eletrônicos (Agarwal *et al.*, 2016; Murff *et al.*, 2011; Huang *et al.*, 2014; Jung *et al.*, 2015; Liao *et al.*, 2015; Carrell *et al.*, 2014). Tais ferramentas de PLN também são capazes de reduzir substancialmente o tempo gasto pelos clínicos para a tarefa de revisão de prontuários (Rahman *et al.*, 2011), otimizando seu tempo de dedicação com o atendimento ao paciente ou outras atividades de pesquisa (Chen *et al.*, 2016; Topaz *et al.*, 2016). As principais etapas envolvidas em um PNL são: segmentação, divisão em sentenças ou palavras (*tokenization*), normalização, análise sintática, análise semântica e classificação (Pons, Braun, Hunink, & Kors, 2016).

Depois de se obter os textos livres de registros médicos, o processamento começa com a segmentação e a obtenção da seleção de seções de interesse (por exemplo, o foco de uma pesquisa pode ser apenas a seção “hipótese diagnóstica” de um laudo de radiologia). Após essa definição, o texto é dividido em frases e/ou palavras – processo conhecido como *tokenization* – que são posteriormente normalizadas ou higienizadas. Dois processos se destacam: o *stemming*, que é a redução de palavras flexionadas (ou derivadas) para seu tronco ou raiz (“carro”, “carros”, “carros”, “carros” são mapeados para “carro”); e a lematização, que representa as palavras por meio do infinitivo dos verbos (“sou”, “é”, “é” é mapeada como “ser”) e masculino singular para substantivos e nomes.

No processo de extração de variáveis, a análise sintática subsequente classifica palavras (nome, verbo, adjetivo), estrutura gramatical (frase verbal, frase nominal) ou relações de dependência (sujeito ou objeto). A análise semântica atribui significado a palavras e frases (por exemplo, sintomas, doenças, procedimentos) e conceitos. Nesta

etapa, definições de dicionários e sinônimos podem ser utilizados, por exemplo, o Metathesaurus do RadLEx (Langlotz, 2006) e do Sistema Médico Unificado de Linguagem (Bodenreider, 2004), ambos especializados em radiologia e disponíveis no idioma inglês.

Depois de extrair as variáveis de interesse no texto livre, a última etapa em um PLN envolve a classificação (por exemplo, se o relatório de um paciente apresenta ou não um diagnóstico de alguma doença). Esse procedimento também é conhecido como fenotipagem do paciente. Para este processamento, pode-se usar métodos baseados em regras, aprendizado de máquina ou métodos híbridos. Na primeira abordagem, os resultados são geralmente satisfatórios quando o domínio está muito bem definido (Chapman, Lee, Kang, & Chapman, 2011; Kirby *et al.*, 2016). O problema é que esse processo requer especialistas em compreensão profunda em cada condição e grandes esforços na elaboração de algoritmos.

Por outro lado, desenvolvimentos recentes com o uso de aprendizagem de máquina no campo da saúde permitiram a fenotipagem de pacientes sem exigir um grande domínio da área (Chen *et al.*, 2017; Esteva *et al.*, 2017; Gehrmann *et al.*, 2018; Gulshan *et al.*, 2016; LeCun, Bengio, & Hinton, 2015).

Integração de dados ômicos

O desenvolvimento de experimentos genéticos resultou em grandes bancos de dados que requerem *pipelines* dedicados de bioinformática, algoritmos e máquinas de computação de alto desempenho para tratar de questões relacionadas à previsão de risco e ao desenvolvimento de um gerenciamento de doenças mais efetivo e personalizado. Atualmente, muitas análises matemáticas e computacionais diferentes são realizadas para identificar variantes causais e selecionar genes cuja expressão é diretamente afetada por eles, obtendo, assim, uma melhor visão sobre quais são os mecanismos moleculares subjacentes ao desenvolvimento de doenças comuns, tais como análise de colocalização, randomização mendeliana e estudos de associação ampla de transcrição (sigla TWAS, do inglês *transcriptome-wide association studies*) (Heinig, 2018). De fato, algumas dessas análises usam imputação para lidar com a dificuldade em ter diferentes tipos de dados das mesmas amostras, a fim de prever os resultados de diferentes experimentos e integrá-los, por exemplo.

Apesar da identificação de milhões de variantes genéticas comuns associadas a uma doença ou fenótipo de doença, elas, individualmente ou em combinação, explicam apenas uma fração da variância do fenótipo. Esse é o caso de várias das doenças cardiovasculares o que levou à busca de baixa frequência e de variantes raras que podem influenciar traços e agrupamentos familiares observados (Manolio *et al.*, 2009). No entanto, essa abordagem ganhou força apenas nos últimos anos, com a redução dos custos do genoma inteiro e do sequenciamento de exomas e o desenvolvimento de grandes consórcios, cujo objetivo principal era o sequenciamento da grande população humana.

Além disso, para ser eficaz e importante na clínica, é necessário entender o papel das variantes gênicas comuns e de baixa frequência dentro da arquitetura genética dos traços da doença. Em 2012, Maurano *et al.* demonstraram que a maioria dos GWAS comuns se encontra em regiões não codificadoras e está hiper-representada em sites de DNA regulatório. Além disso, estas variantes perturbam o reconhecimento de

sítios de fatores de transcrição que alteram os estados de cromatina alélica e parecem enriquecidos em tecidos relacionados com características. Estudos subsequentes confirmaram esses achados em diferentes doenças e características (Smemo *et al.*, 2014; Soldner *et al.*, 2016). As informações geradas por diferentes dados genômicos foram usadas para desenvolver algoritmos para prever o risco de doenças. Inicialmente, a comunidade científica focou em estratégias simples baseadas em estatísticas clássicas (por exemplo, regressões lineares e logísticas múltiplas) (Cox *et al.*, 2014; Fava *et al.*, 2013; Justesen *et al.*, 2015). Atualmente, é preciso usar diferentes técnicas de aprendizado de máquina, como aprendizagem profunda, para identificar padrões genéticos, bem como desenvolver preditores adequados de risco de doença usando informações genômicas (Li *et al.*, 2018).

Assim, a integração de diferentes dados ômicos é fundamental para entender a influência dessas variantes genéticas no desenvolvimento da característica, o que permitirá que elas sejam usadas em algoritmos de risco preditivo e adaptem o gerenciamento de doenças do paciente.

Comentários finais

Os desafios para os próximos anos são promissores. Isso decorre de um momento em que há muitos desafios que podem ser encarados com mais eficiência com as novas tecnologias, embora, ao mesmo tempo, sejam gastas somas vultosas com sistemas de saúde sob vários aspectos pouco integrados e disfuncionais, o que cria uma “tempestade quase perfeita”. Por um lado, existem casos como o do sistema americano, cujos gastos em saúde representam aproximadamente 20% do Produto Interno Bruto (PIB), que é a maior economia do planeta, e o país não apresenta os melhores indicadores de saúde populacionais. De outro lado, o caso do Brasil, que tem um gasto *per capita* baixo, um sistema público bem desenhado e estruturado, mas que, na realidade, devido ao seu subfinanciamento, é disfuncional e precisa ser aprimorado. Essas duas realidades carecem de reformas e as novas metodologias baseadas em Inteligência Artificial, pelas suas características de atuação transversal e em várias etapas deste processo, terão papel importante na racionalização dos sistemas de saúde, no avanço e implementação da medicina individualizada para promoção da saúde, no desenvolvimento de estratégias individuais de prevenção ou assistindo as decisões para minimizar o efeito das doenças de maneira mais racional.

Referências

- Agarwal, V., Podchiyska, T., Banda, J. M., Goel, V., Leung, T. I., Minty, E. P., . . . Shah, N. H. (2016). Learning statistical models of phenotypes using noisy labeled training data. *Journal of the American Medical Informatics Association : JAMIA*, 23(6), 1166–1173.
- Altshuler, D., & Donnelly, P. (2005). A haplotype map of the human genome. *Nature*, 437(7063), 1299–1320.
- Bodenreider, O. (2004). The Unified Medical Language System (UMLS): integrating biomedical terminology. *Nucleic Acids Research*, 32, D267–D270.
- Carrell, D. S., Halgrim, S., Tran, D. T., Buist, S. M., Chubak, J., Chapman, W., & Savova, G. (2014). Using natural language processing to improve efficiency of manual chart abstraction in research: The case of breast cancer recurrence. *American Journal of Epidemiology*, 179(6), 749–758.
- Chapman, B. E., Lee, S., Kang, H. P., & Chapman, W. W. (2011). Document-level classification of CT pulmonary angiography reports based on an extension of the ConText algorithm. *Journal of Biomedical Informatics*, 44(5), 728–737.
- Chen, L., Guo, U., Illipparambil, L. C., Netherton, M. D., Sheshadri, B., Karu, E., . . . Mehta, P. H. (2016). Racing against the clock: Internal medicine residents' time spent on electronic health records. *Journal of Graduate Medical Education*, 8(1), 39–44.
- Chen, M. C., Ball, R. L., Yang, L., Moradzadeh, N., Chapman, B. E., Larson, D. B., . . . Lungren, M. P. (2017). Deep learning to classify radiology free-text reports. *Radiology*, 286(3), 845–852.
- Cireşan, D. C., Giusti, A., Gambardella, L. M., & Schmidhuber, J. (2013). Mitosis detection in breast cancer histology images with deep neural networks. In K. Mori, I. Sakuma, Y. Sato, C. Barillot, & N. Navab (Eds.), *Medical image computing and computer-assisted intervention – MICCAI 2013* (pp. 411–418). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Cox, A. J., Hsu, F. C., Ng, M. C. Y., Langefeld, C. D., Freedman, B. I., Carr, J. J., & Bowden, D. W. (2014). Genetic risk score associations with cardiovascular disease and mortality in the diabetes heart study. *Diabetes Care*, 37(4), 1157–1164.
- Devasahayam, S. R. (2013). *Signals and systems in biomedical engineering: Singal processing and physiological systems modeling*. Springer.
- ENCODE Project Consortium. (2004). The ENCODE (ENCyclopedia of DNA elements) Project. *Science*, 306(5696), 636–640.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542, 115.
- Evangelou, E., Warren, H. R., Mosen-Ansorena, D., Mifsud, B., Pazoki, R., Gao, H., . . . the Million Veteran Program (2017). Genetic analysis of over one million people identifies 535 novel loci for blood pressure. *BioRxiv*, 50(October), 198234.
- Faust, O., & Bairy, M. G. (2012). Nonlinear analysis of physiological signals: a review. *Journal of Mechanics in Medicine and Biology*, 12(4), 1240015.

- Fava, C., Sjögren M., Montagnana M., Danese, E., Almgren, P., Engström G., . . . Melander, O. (2013). Prediction of blood pressure changes over time and incidence of hypertension by a genetic risk score in Swedes. *Hypertension*, 61(2), 319–326.
- Gehrmann, S., Dernoncourt, F., Li, Y., Carlson, E. T., Wu, J. T., Welt, J., . . . Celi, L. A. (2018). Comparing deep learning and concept extraction based methods for patient phenotyping from clinical narratives. *PLOS ONE*, 13(2), e0192360.
- Giri, A., Hellwege, J. N., Keaton, J. M., Park, J., Qiu, C., Warren, H. R., . . . Hung, A. M. (2019). Trans-ethnic association study of blood pressure determinants in over 750,000 individuals. *Nature Genetics*, 51(1), 51–62.
- Greenspan, H., Ginneken, B. van, & Summers, R. M. (2016). Guest editorial deep learning in medical imaging: Overview and future promise of an exciting new technique. *IEEE Transactions on Medical Imaging*, 35(5), 1153–1159.
- Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., . . . Webster, D., R. (2016). Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA*, 316(22), 2402–2410.
- Heinig, M. (2018). Using gene expression to annotate cardiovascular GWAS Loci. *Frontiers in Cardiovascular Medicine*, 5, 59.
- Hof, R. D. (2013). 10 breakthrough technologies 2013: Deep learning. *MIT Technology Review*. Recuperado em 17 maio, 2020, de <https://www.technologyreview.com/10-breakthrough-technologies/2013/>
- Howie, B. N., Donnelly, P., & Marchini, J. (2009). A flexible and accurate genotype imputation method for the next generation of genome-wide association studies. *PLoS Genetics*, 5(6), e1000529–e1000529.
- Huang, S. H., LePendur, P., Iyer, S. V., Tai-Seale, M., Carrell, D., & Shah, N. H. (2014). Toward personalizing treatment for depression: Predicting diagnosis and severity. *Journal of the American Medical Informatics Association : JAMIA*, 21(6), 1069–1075.
- Isin, A., & Ozdalili, S. (2017). Cardiac arrhythmia detection using deep learning. *Procedia Computer Science*, 120, 268–275.
- Jung, K., LePendur, P., Iyer, S., Bauer-Mehren, A., Percha, B., & Shah, N. H. (2015). Functional evaluation of out-of-the-box text-mining tools for data-mining tasks. *Journal of the American Medical Informatics Association: JAMIA*, 22(1), 121–131.
- Justesen, J. M., Allin, K. H., Sandholt, C. H., Borglykke, A., Krarup, N. T., Grarup, N., . . . Pedersen, O. (2015). Interactions of lipid genetic risk scores with estimates of metabolic health in a Danish population. *Circulation: Cardiovascular Genetics*, 8(3), 465–472.
- Kirby, J. C., Speltz, P., Rasmussen, L. V., Basford, M., Gottesman, O., Peissig, P. L., . . . Denny, J. C. (2016). PheKB: A catalog and workflow for creating electronic phenotype algorithms for transportability. *Journal of the American Medical Informatics Association : JAMIA*, 23(6), 1046–1052.
- Krittanawong, C., Zhang, H., Wang, Z., Aydar, M., & Kitai, T. (2017). Artificial intelligence in precision cardiovascular medicine. *Journal of the American College of Cardiology*, 69(21), 2657–2664.

- Kundaje, A., Meuleman, W., Ernst, J., Bilenky, M., Yen, A., Heravi-Moussavi, A., . . . Kellis, M. (2015). Integrative analysis of 111 reference human epigenomes. *Nature*, 518(7539), 317–330.
- Långkvist, M., Karlsson, L., & Loutfi, A. (2012). Sleep stage classification using unsupervised feature learning. *Advances in Artificial Neural Systems*, 2012, 1–9.
- Langlotz, C. P. (2006). RadLex: A New method for indexing online educational materials. *RadioGraphics*, 26(6), 1595–1597.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521, 436.
- Li, J., Pan, C., Zhang, S., Spin, J. M., Deng, A., Leung, L. L. K., . . . Snyder, M. (2018). Decoding the genomics of abdominal aortic aneurysm. *Cell*, 174(6), 1361–1372.e10.
- Liao, K. P., Cai, T., Savova, G. K., Murphy, S. N., Karlson, E. W., Ananthakrishnan, A. N., . . . Kohane, I. (2015). Development of phenotype algorithms using electronic medical records and incorporating natural language processing. *BMJ : British Medical Journal*, 350.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., . . . Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88.
- Manolio, T. A., Collins, F. S., Cox, N. J., Goldstein, D. B., Hindorff, L. A., Hunter, D. J., . . . Visscher, P. M. (2009). Finding the missing heritability of complex diseases. *Nature*, 461(7265), 747–753.
- Mathews, S. M., Kambhamettu, C., & Barner, K. E. (2018). A novel application of deep learning for single-lead ECG classification. *Computers in Biology and Medicine*, 99, 53–62.
- Maurano, M. T., Humbert, R., Rynes, E., Thurman, R. E., Haugen, E., Wang, H., . . . Stamatoyannopoulos, J. A. (2012). Systematic localization of common disease-associated variation in regulatory DNA. *Science (New York, N.Y.)*, 337(6099), 1190–1195.
- Mirowski, P. W., LeCun, Y., Madhavan, D., & Kuzniecky, R. (2008). Comparing SVM and convolutional networks for epileptic seizure prediction from intracranial EEG. *2008 IEEE Workshop on Machine Learning for Signal Processing*, 244–249.
- Murff, H. J., FitzHenry, F., Matheny, M. E., Gentry, N., Kotter, K. L., Crimin, K., . . . Speroff, T. (2011). Automated identification of postoperative complications within an electronic medical record using natural language processing. *JAMA*, 306(8), 848–855.
- Oliveira, D. A. B., Macedo, M. M. G., Nicz, P., Campos, C., Lemos, P., & Gutierrez, M. A. (2018). Coronary calcification identification in optical coherence tomography using convolutional neural networks. *Proc. SPIE, Medical Imaging 2018: Biomedical Applications in Molecular, Structural, and Functional Imaging*, 10578, 105781Y–10578–7.
- Pons, E., Braun, L. M. M., Hunink, M. G. M., & Kors, J. A. (2016). Natural Language Processing in Radiology: A Systematic Review. *Radiology*, 279(2), 329–343.
- Rahhal, M. M. Al, Bazi, Y., AlHichri, H., Alajlan, N., Melgani, F., & Yager, R. R. (2016). Deep learning approach for active classification of electrocardiogram signals. *Information Sciences*, 345, 340–354.
- Rahman, S., Majumder, M. A. A., Shaban, S. F., Rahman, N., Ahmed, M., Abdulrahman, K. B., & D'Souza, U. J. (2011). Physician participation in clinical research and trials: Issues and approaches. *Advances in Medical Education and Practice*, 2, 85–93.

- Shen, D., Wu, G., & Suk, H.-I. (2017). Deep learning in medical image analysis. *Annual Review of Biomedical Engineering*, 19(1), 221–248.
- Smemo, S., Tena, J. J., Kim, K. H., Gamazon, E. R., Sakabe, N. J., Gómez-Marín, C., . . . Nóbrega, M. A. (2014). Obesity-associated variants within FTO form long-range functional connections with IRX3. *Nature*, 507(7492), 371–375.
- Soldner, F., Stelzer, Y., Shivalila, C. S., Abraham, B. J., Latourelle, J. C., Barrasa, M. I., . . . Jaenisch, R. (2016). Parkinson-associated risk variant in distal enhancer of α -synuclein modulates target gene expression. *Nature*, 533(7601), 95–99.
- Stranger, B., Brigham, L., Hasz, R., Hunter, M., Johns, C., Johnson M., . . . Montgomery S. B. (2017). Enhancing GTEx by bridging the gaps between genotype, gene expression, and disease. *Nature Genetics*, 49, 1664–1670.
- Tajbakhsh, N., Gotway, M. B., & Liang, J. (2015). Computer-aided pulmonary embolism detection using a novel vessel-aligned multi-planar image representation and convolutional neural networks. In *Lecture Notes in Computer Science* (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics) (Vol. 9350, pp. 62–69).
- Tajbakhsh, N., Gurudu, S. R., & Liang, J. (2015). Automatic polyp detection in colonoscopy videos using an ensemble of convolutional neural networks. *2015 IEEE 12th International Symposium on Biomedical Imaging (ISBI)*, 79–83.
- Teixeira, S. K., Pereira, A. C., & Krieger, J. E. (2018). Genetics of resistant hypertension: The missing heritability and opportunities. *Current Hypertension Reports*, 20(6), 48.
- The 1000 Genomes Project Consortium. (2012). An integrated map of genetic variation from 1,092 human genomes. *Nature*, 491(7422), 56–65.
- Topaz, M., Lai, K., Dowding, D., Lei, V. J., Zisberg, A., Bowles, K. H., & Zhou, L. (2016). Automated identification of wound information in clinical notes of patients with heart diseases: Developing and validating a natural language processing application. *International Journal of Nursing Studies*, 64, 25–31.
- Visscher, P. M., Wray, N. R., Zhang, Q., Sklar, P., McCarthy, M. I., Brown, M. A., & Yang, J. (2017). 10 years of GWAS discovery: Biology, function, and translation. *American Journal of Human Genetics*, 101(1), 5–22.
- Wainberg, M., Merico, D., Delong, A., & Frey, B. J. (2018). Deep learning in biomedicine. *Nature Biotechnology*, 36, 829.
- Wang, D., & Shang, Y. (2013). Modeling physiological data with deep belief networks. *International Journal of Information and Education Technology (IJJET)*, 3(5), 505–511.

COVID-19: informação e decisão para adotar o lockdown¹

Eduardo Massad²

Introdução

Em 26 de fevereiro de 2020, um homem de 61 anos, de São Paulo, que retornou da Itália, testou positivo para o SARS-CoV-2, causador da COVID-19. Embora haja alguma controvérsia sobre isso, pode-se considerar este como o paciente zero da doença no Brasil. Daquele momento até 11 de maio de 2020, confirmaram-se 162.699 casos, a maior parte deles no estado de São Paulo, causando 11.123 mortes e levando algumas cidades ao colapso do sistema de atendimento em saúde.

O Brasil encontra-se entre os países com os maiores índices de transmissibilidade do SARS-CoV-2, com reprodutibilidade no início da epidemia de 3,5. Isso significa que cada caso no início era capaz de infectar outros 3,5 indivíduos suscetíveis. Após algum esforço no sentido de implementar medidas de distanciamento social, o país conseguiu reduzir esse índice inicial em 50%. Com essas medidas, cada paciente passou a ser capaz de infectar 1,7 outros suscetíveis. Mantendo esse ritmo de crescimento, é possível prever uma dimensão catastrófica ao final da pandemia, com o total de casos chegando à marca de 34 milhões de infecções.

Neste artigo, apresentam-se técnicas matemáticas e computacionais que permitem projeções sobre os principais valores de interesse epidemiológicos, com o objetivo de ajudar as autoridades de saúde pública a planejar as melhores estratégias de mitigação da epidemia.

¹ No momento de entrega deste artigo à publicação, em 17 de maio de 2020, havia 241.080 casos confirmados de infectados pelo novo coronavírus no Brasil e 16.118 óbitos, segundo dados oficiais do Ministério da Saúde. Ao concluir a edição da pesquisa TIC Saúde 2019, no dia 29 de agosto de 2020, o país tinha 3.846.153 casos e 120.462 óbitos, o segundo país no número acumulado de mortos após os Estados Unidos, segundo o Boletim Epidemiológico Especial do Ministério da Saúde. Recuperado em 2 setembro, 2020, de <https://coronavirus.saude.gov.br/boletins-epidemiologicos>

² Professor titular da Escola de Matemática Aplicada da Fundação Getúlio Vargas (EMAp/FGV). Médico e físico, doutor em Patologia Experimental pela Universidade de São Paulo (USP). Professor titular aposentado de Informática Médica da USP e chefe do Departamento de Medicina Legal da USP. Professor honorário de Doenças Infecciosas da London School of Hygiene and Tropical Medicine, professor visitante de Medicina da Universidade Nacional de Cingapura e professor de Estatística e Psicologia na Universidade de Derby.

Como é possível fazer previsões com tão pouca informação?

Desde os primeiros modelos matemáticos propostos para a descrição da dinâmica da varíola por Daniel Bernoulli, no século 18, houve um progresso exponencial nas aplicações dessas ferramentas no planejamento de estratégias de saúde pública (Bernoulli, 1995). A partir dos anos 1970, houve grande avanço nessa área e, hoje em dia, os modelos matemáticos e computacionais já fazem parte do ferramental dos epidemiologistas no mundo todo.

Os modelos que têm tido aplicação mais disseminada na compreensão da dinâmica das epidemias são os compartimentais de natureza determinística e/ou estocástica. Eles consistem em dividir a população total em “compartimentos” que correspondem aos diversos estágios da evolução natural da infecção. No modelo mais simples, a população total é dividida em “suscetíveis” e “infectados” (S-I). A partir de meados da década de 1920, entretanto, com os desenvolvimentos de Kermack e Mackendrick (1927), um terceiro compartimento foi acrescentado, correspondente aos pacientes “removidos” da cadeia de transmissão, ou por morte ou por recuperação da infecção. Esses modelos são denominados S-I-R. Sobre essa estrutura básica, uma infinidade de sofisticções foi sendo acrescentada, dependendo da complexidade do ciclo das infecções que se pretendia modelar.

Na infecção pelo SARS-CoV-2, pelo fato de haver um período de incubação relevante, o modelo que mais se adequa a descrever a dinâmica da infecção é o da classe S-E-I-R, na qual o “E” corresponde aos indivíduos “expostos” ao agente infeccioso. Esse é o modelo que tem sido usado no mundo todo para explicar a pandemia da COVID-19.

Com base nessa estrutura compartimental acrescenta-se um sistema de equações que descreve o “fluxo” entre os diversos compartimentos, reproduzindo, dessa forma, a dinâmica da história natural da evolução da epidemia. Os modelos passam, então, a ser simulados em ambiente computacional com parâmetros que determinam sua dinâmica, obtidos a partir de deduções matemáticas e dos dados empíricos da epidemia. A partir dos resultados das simulações, as projeções são feitas sobre o comportamento de cada variável em instantes futuros e as estratégias de intervenção são simuladas de modo a se estabelecer qual a melhor maneira de controlar a epidemia.

Entre os fatores que determinam a intensidade de transmissão de um agente infeccioso, destaca-se a reprodutibilidade basal da infecção, denotada R_0 , que é definida como o número de infecções secundárias que um único caso índice é capaz de gerar em uma população inteiramente suscetível ao longo de seu período de infecciosidade. O R_0 é uma razão entre a incidência da infecção pela soma das taxas de remoção do estado infeccioso; a Figura 1 ilustra essa dinâmica.

FIGURA 1

DINÂMICA DA REPRODUTIBILIDADE BASAL DA INFECÇÃO



FONTE: ELABORAÇÃO PRÓPRIA.

Uma vez que o número de suscetíveis cai de 100% à medida que o tempo passa, definimos outro parâmetro que é a reprodutibilidade efetiva, denotada $R(t)$, e definida como o número de infecções secundárias que cada caso gera em cada instante de tempo. A reprodutibilidade efetiva é o produto de R_0 pela fração de suscetíveis em cada instante de tempo. Assim, se denotamos os suscetíveis em cada instante por $S_H(t)$, e a população total por $N_H(t)$, $R(t)$ é obtido por:

$$R(t) = R_0 \frac{S_H(t)}{N_H(t)}$$


Nota-se que quando $t = 0$, $S_H(t) = N_H(t)$, e $R(t) = R_0$. Esse é o parâmetro " R_t " que tem sido veiculado na mídia.

Um modelo para a COVID-19

Como acima mencionado, é possível trabalhar com um modelo de estrutura S-E-I-R para estudar a dinâmica da COVID-19 em uma população de suscetíveis. Uma possível estrutura de modelo está ilustrada na Figura 2.

FIGURA 2

ESTRUTURA DE MODELO S-E-I-R PARA A DINÂMICA DA COVID-19



FONTE: ELABORAÇÃO PRÓPRIA.

Neste modelo, $S_H(t)$ representa a população de indivíduos suscetíveis, $E_H(t)$ a de expostos ao vírus, $I_H(t)$ a de indivíduos que são infectados pelo vírus, $G_H(t)$ a de indivíduos com doença grave, necessitando de assistência hospitalar, e finalmente, $R_H(t)$ representa a população de indivíduos recuperados da doença.

Os parâmetros do modelo são: Λ_H , que representa a taxa de crescimento da população por nascimento ou migração; μ_H , que representa a taxa de mortalidade por todas as outras causas que não o vírus; β , que representa a taxa de contatos potencialmente infectantes; δ_H , que representa o inverso do período de incubação; α_H , que representa a taxa de mortalidade pela doença; π_H , que representa a taxa de evolução para o estado de doença grave; σ_H , que representa a taxa de mortalidade adicional dos doentes graves; γ_H , que representa a taxa de recuperação dos infectados; e θ_H , que representa a taxa de recuperação dos doentes graves. Os parâmetros p e q foram introduzidos para ponderar a contribuição das variáveis $E_H(t)$ e $I_H(t)$ para a infecção dos suscetíveis. Finalmente, o parâmetro κ foi introduzido para simular as medidas de distanciamento social. Esse parâmetro varia de 0 a 1.

A dinâmica desse modelo é descrita pelo seguinte sistema de equações:

$$\begin{aligned}\frac{d}{dt}S_H(t) &= -\beta\kappa S_H \frac{(pE_H + qI_H)}{N_H} - \mu_S S_H + \Lambda_H \\ \frac{d}{dt}E_H(t) &= \beta\kappa S_H \frac{(pE_H + qI_H)}{N_H} - (\mu_S + \delta_H)E_H \\ \frac{d}{dt}I_H(t) &= \delta_H E_H - (\mu_S + \alpha_H + \gamma_H + \pi_H)I_H \\ \frac{d}{dt}G_H(t) &= \pi_H I_H - (\mu_S + \sigma_H + \theta_H)G_H \\ \frac{d}{dt}R_H(t) &= \gamma_H I_H + \theta_H G_H - \mu_S R_H\end{aligned}$$

O R_0 deste modelo é dado pela seguinte equação:

$$R_0 = \frac{\delta_H \beta \kappa}{(\delta_H + \mu_H)(\gamma_H + \alpha_H + \mu_H + \pi_H)}$$

O valor de R_0 pode ser calculado a partir da taxa de crescimento exponencial do início da epidemia, φ pela equação:

$$R_0 = \varphi^2 + \frac{\varphi [(\delta_H + \mu_H) + (\gamma_H + \alpha_H + \mu_H + \pi_H)]}{(\delta_H + \mu_H)(\gamma_H + \alpha_H + \mu_H + \pi_H)} + 1$$

A taxa de incidência, definida como o número de casos novos por unidade de tempo, denotada $Inc(t)$, é calculada pela equação:

$$Inc(t) = \beta \kappa S_H(t) \frac{I_H(t)}{N_H(t)}$$

O número de casos em um intervalo de tempo Δt é dado por:

$$Casos(t) = \int_{t_0}^{t_0+\Delta t} Inc(t) dt$$

O número de casos graves em um intervalo de tempo Δt é dado por:

$$Graves(t) = \int_{t_0}^{t_0+\Delta t} \pi(t) I_H(t) dt$$

E o número de mortes é dado por:

$$Mortes(t) = \int_{t_0}^{t_0+\Delta t} \left\{ \left[(\mu_H + \alpha_H) I_H(t) \right] + (\mu_H + \sigma_H) G_H(t) \right\} dt$$

A taxa de mortalidade dos pacientes graves, σ_H , foi considerada como uma função do número de pacientes, de modo que ela possa aumentar conforme o sistema de assistência hospitalar sature.

A função escolhida foi:

$$\sigma_H(t) = \sigma_H(0) + [a_0 + a_1 t] [\theta(t_c - t_0)]$$


onde $\theta(t_c - t_0)$ é a função degrau de Heaviside t_c e é o instante em que o sistema hospitalar entra em colapso.

Como esse modelo se comporta em relação aos dados reais da epidemia?

Os gráficos abaixo mostram o resultado da simulação do modelo para o número de casos de infecção e de mortes até a data de 11 de maio de 2020.

GRÁFICO 1

EVOLUÇÃO DO NÚMERO DE CASOS DE COVID-19 A PARTIR DAS PROJEÇÕES DO MODELO




FONTE: ELABORAÇÃO PRÓPRIA.

A linha vermelha do Gráfico 1 mostra o crescimento inicial exponencial, que correspondia a um valor de $R_0 = 3,5$, sem, portanto, nenhuma medida de mitigação. Essa curva representa o crescimento “natural” da epidemia. Os pontos azuis representam os casos reais de COVID-19 e a curva pontilhada, o resultado da simulação do modelo com o parâmetro de contato β reduzido em 50%, representando um distanciamento social de 50%. O $R(t)$, neste caso, cai proporcionalmente em 50% para o valor de 1,75, ou seja, na situação atual, cada caso gera, em média, 1,75 outros casos, um crescimento ainda muito alto.

O Gráfico 2 mostra o resultado da simulação do modelo com os parâmetros correspondentes à curva pontilhada do Gráfico 1, para os casos de mortes até o momento.

GRÁFICO 2
EVOLUÇÃO DO NÚMERO DE MORTES DE COVID-19 A PARTIR DAS PROJEÇÕES DO MODELO



FONTE: ELABORAÇÃO PRÓPRIA.

No Gráfico 2, os pontos vermelhos denotam os dados reais de mortalidade acumulada até meados de maio e a linha contínua representa o resultado da simulação do modelo. Pode-se notar dos gráficos que o modelo recupera os dados empíricos da epidemia com boa acurácia, o que significa que o $R(t)$ no momento é de 1,75, equivalente a um distanciamento social de 50% em média para o país e, ainda, que o modelo tem confiabilidade suficiente para a realização de projeções.


O que significa o “achatoamento da curva”?

Muito tem se falado sobre o “achatoamento da curva”. Ele diz respeito à chamada “curva epidêmica”, que nada mais é do que a curva de incidência, ou seja, o número de casos novos por unidade de tempo. Ela tem a forma de um sino, atingindo um pico, o assim chamado “pico da epidemia”, caindo em seguida até valores muito próximos de zero, ou estabilizando-se em algum equilíbrio endêmico (neste último caso $R(t)=1$).

O Gráfico 3 ilustra o fenômeno de “achatoamento da curva” para nosso modelo em que o R_0 inicial cai de 3,5 para o $R(t)$ de 1,75.

GRÁFICO 3

EVOLUÇÃO DA INCIDÊNCIA DIÁRIA DE COVID-19 A PARTIR DAS PROJEÇÕES DO MODELO



FONTE: ELABORAÇÃO PRÓPRIA.

A linha vermelha representa, no Gráfico 3, o crescimento “natural” da epidemia, sem medidas de contenção ($R_0=3,5$) e a linha azul representa a incidência diária de infecção com o equivalente a um distanciamento social de 50% ($R(t)=1,75$). Nota-se que a curva pós-intervenção se “achata” de fato, mas o pico epidêmico se desloca para frente. Isso significa que, se por um lado o número de casos cai significativamente, por outro lado a epidemia vai durar mais tempo.


Por que o Brasil precisa adotar o *lockdown*?

Como se pode observar, o Brasil ainda está longe de controlar essa epidemia. A taxa de crescimento da curva ainda é extremamente elevada e as projeções do modelo apontam para um cenário de caos no sistema de saúde.

O chamado *lockdown*, adotado em todos os países que conseguiram controlar a epidemia até o momento, significa uma obrigatoriedade de permanecer em casa, sujeito a sanções como multas e até prisão. Ele tem por objetivo reduzir o valor de $R(t)$ para abaixo de 1, quando um caso não é capaz de gerar outro caso de infecção. Nessa situação, a curva epidêmica cai drasticamente. Para o caso do Brasil, que começou a epidemia com valor de $R_0=3,5$, isso significa aumentar o distanciamento para valores acima de 70%.

As projeções do modelo apontam para uma crescente taxa de letalidade, como se observa no Gráfico 4.

GRÁFICO 4

EVOLUÇÃO DA LETALIDADE DE COVID-19 A PARTIR DAS PROJEÇÕES DO MODELO

FONTE: ELABORAÇÃO PRÓPRIA.

No Gráfico 4, a sigla CFR significa *case fatality rate*, ou seja, a letalidade, definida como a relação entre o número de mortes sobre o número de casos notificados. Nota-se que a taxa de letalidade aumenta a cada dia. Isso se deve, principalmente, pela saturação do sistema hospitalar, quando o número de pessoas com a COVID-19 passa a morrer com uma probabilidade muito maior do que a observada entre os países que conseguiram controlar a epidemia. Em algumas cidades do país, as pessoas já morreram por falta de leitos hospitalares, principalmente de leitos de UTI, e pela falta de respiradores. O Brasil como um todo tem taxas de letalidade muito altas em comparação com outros países. A Tabela 1 mostra as taxas de letalidade atuais para alguns estados brasileiros:

TABELA 1

CASOS, ÓBITOS E TAXA DE LETALIDADE DE COVID-19 - TOTAL BRASIL E UNIDADES DA FEDERAÇÃO


	Casos	Óbitos	Letalidade (%)
Brasil	168 331	11 519	6,84
Rio de Janeiro	17 939	1 770	9,87
São Paulo	46 131	37 433	8,12
Amazonas	12 919	1 035	8,01
Ceará	17 599	1 189	6,76
Pernambuco	13 769	1 087	7,89

FONTE: ELABORAÇÃO PRÓPRIA.

No Gráfico 5, é apresentada a simulação do modelo para o número de mortos por faixa etária, caso os índices de distanciamento social se mantenham na casa dos 50%. As barras azuis representam a situação sem mitigação e as vermelhas com 50% de distanciamento social.

GRÁFICO 5

NÚMERO DE MORTES A PARTIR DO MODELO, POR FAIXA ETÁRIA - PROJEÇÃO SEM MITIGAÇÃO X DISTÂNCIAMENTO SOCIAL




FONTE: ELABORAÇÃO PRÓPRIA.

Na simulação da hipótese de o Brasil adotar o *lockdown* e conseguir aumentar o distanciamento para valores maiores que 70%, o que se poderia observar é o que está ilustrado no Gráfico 6.

GRÁFICO 6

EVOLUÇÃO DA INCIDÊNCIA DIÁRIA DE COVID-19 A PARTIR DO MODELO



FONTE: ELABORAÇÃO PRÓPRIA.


No Gráfico 6, a curva verde representa a incidência “natural” da epidemia, a curva vermelha o distanciamento social de 50% e a curva azul o resultado de um *lockdown* com distanciamento de 71%. O gráfico está em escala logarítmica para que a visualização das diferenças seja possível. A rápida queda exponencial do número de casos novos por dia, representada na curva azul, demonstra a eficácia do *lockdown* em controlar a epidemia.

Quando será possível relaxar a quarentena?

Com níveis de distanciamento social médio de apenas 50% até o final de maio, quando o ideal seria acima de 70%, o Brasil se encontra longe de controlar essa epidemia. Sem a adoção de um *lockdown* amplo e efetivo, a projeção da curva epidêmica deve atingir um pico no dia 14 de julho de 2020, conforme se observa no Gráfico 7.

GRÁFICO 7

PROJEÇÃO DA CURVA EPIDÊMICA DE COVID-19 SEM A ADOÇÃO DE LOCKDOWN



FONTE: ELABORAÇÃO PRÓPRIA.

Sem que nada seja feito, o pico da curva epidêmica pode atingir os valores de mais de 65 mil casos novos por dia nesse momento, estendendo-se até o mês de outubro. Mas as estratégias de abertura do país não podem sequer começar a ser discutidas no momento do pico da epidemia. Qual o momento em que o $R(t)$ vai atingir o limiar da unidade?


Sabe-se que, em todo surto epidêmico de qualquer infecção, os valores de reprodutibilidade caem conforme a fração de suscetíveis vai diminuindo com o tempo, iniciando-se com o valor de R_0 e caindo até que não haja mais suscetíveis o suficiente para manter o crescimento da curva epidêmica. Esse momento é chamado de “imunidade de rebanho” (IR). Esta IR é uma função explícita de R_0 e pode ser calculada como:

$$IR = 1 - \frac{1}{R_0}$$

No caso da situação sem as medidas de mitigação, quando $R_0=3.5$, a imunidade de rebanho representava 71% da população suscetível (daí a necessidade de distanciamento social de mais de 70%). Com o valor atual de $R(t)$, a IR de rebanho será atingida quando a fração de indivíduos que já tiveram a doença (a variável R_H do modelo) alcançarem 43% em relação à população total. Isso deve ser atingido no dia 30 de julho de 2020, conforme se observa no Gráfico 8.

GRÁFICO 8

PROJEÇÃO DE CASOS DE COVID-19 SEGUNDO A EVOLUÇÃO DA IMUNIDADE DE REBANHO



FONTE: ELABORAÇÃO PRÓPRIA.

A partir dessa data, as simulações das possíveis estratégias de relaxamento da quarentena deverão ser realizadas por meio do modelo, para se evitar um recrudescimento da epidemia. Antes disso, nenhum relaxamento das medidas de distanciamento deveria ser discutido. Entretanto, acredita-se que só existe algum grau de confiabilidade se o *lockdown* fosse decretado, ou então se a discussão sobre o relaxamento das medidas começasse a partir de meados de setembro, quando a curva epidêmica estivesse em níveis suficientemente baixos.

Conclusões

Como acima mencionado, o Brasil está entre os países com os maiores índices de disseminação da COVID-19 do mundo. Os valores iniciais de R_0 apontam para um cenário verdadeiramente catastrófico, sem precedentes na pandemia que ainda afeta vários países.

As medidas de mitigação que foram adotadas até fins de maio, com exceção de algumas tentativas (ainda não bem-sucedidas) de *lockdown* de alguns estados, foram extremamente tímidas e os índices de distanciamento social ainda ficaram longe dos

valores ideais. São Paulo, o estado mais afetado pela epidemia, apresentou índices de distanciamento social abaixo da média nacional.

A menos que o país como um todo adotasse o *lockdown*, proibindo de fato as pessoas de saírem de casa e paralisando todas as atividades não essenciais, a hipótese provável é de se caminhar para um quadro preocupante, com um número de mortes que pode chegar a centenas de milhares até o fim da epidemia. Só no estado de São Paulo, o modelo prevê que nos próximos meses o número de novas infecções por dia passe dos 100 mil, como também conclui um estudo elaborado por pesquisadores da Unicamp.³

Com os índices de distanciamento adotados até maio, de 50% na média do país, a previsão é que a epidemia atingiria seu pico na primeira quinzena de julho. Se, por outro lado, fosse possível chegar ao alvo de 70% de isolamento, a curva epidêmica poderia cair exponencialmente e as autoridades poderiam começar a discutir a reabertura do país.

Finalmente, cabe ressaltar que todas as projeções feitas com o modelo aqui proposto estão sujeitas a enormes incertezas, e que o modelo só permite previsões confiáveis se suas premissas e os valores dos seus parâmetros tiverem grau suficiente de credibilidade. Afinal, como dizia o eminente estatístico George Box: “todos os modelos são errados, mas alguns modelos são úteis” (Box, 1979, p. 202).

³ Projeções feitas com um modelo matemático desenvolvido na Universidade Estadual de Campinas (Unicamp) indicam que a adoção de *lockdown* obrigatório no estado de São Paulo será inevitável caso o nível de isolamento social não suba significativamente nas próximas semanas, começando no dia 12 de maio de 2020. Ver Toledo, K. (2020). *Lockdown* será inevitável em SP se isolamento não subir nas próximas semanas, indica estudo (Agência Fapesp). Recuperado em 17 maio, 2020, de <http://agencia.fapesp.br/lockdown-i-sera-inevitavel-em-sp-se-isolamento-nao-subir-nas-proximas-semanas-indica-estudo/33147/>

Referências

Bernoulli, D. (1995). Essai d'une nouvelle analyse de la mortalite causee par apeteite verole (Publicado originalmente em 1766, tradução para o inglês intitulada "An attempt at a new analysis of the mortality caused by smallpox and of the advantages of inoculation to prevent it"). In S. Haberman, & T.A. Sibbett (Eds.). *History of Actuarial Science* (Vol. 8, Multiple Decrement and Multiple State Models). Londres: William Pickering.

Box, G. E. P. (1979). Robustness in the strategy of scientific model building. In R. L. Launer, & G. N. Wilkinson (Eds.). *Robustness in Statistics* (pp. 201–236). Academic Press.

Kermack, W. O., & MacKendrick, A. G. (1927). A contribution to the mathematical theory of epidemics. *Proceedings of the Royal Society*, 115, 700–721.

Massad, E., Menezes, R. X., Silveira, P. S. P., & Ortega, N. R. S. (2004). *Métodos quantitativos em medicina*. São Paulo: Editora Manole.



ENGLISH

Foreword

The advent of the Internet took place with the first data packets exchanged on the Advanced Research Projects Agency Network (ARPANET) in 1969. Half a century later, many issues have arisen due to the opportunities and risks generated by intensive use of information and communication technologies (ICT) in society. The remarkable advancement of informatics during this period has been based on enormous expansion of computing power and data storage and transmission. In addition to the development of numerous applications, this has given fresh encouragement to old fields of research, with results in the most diverse sectors.

Special mention goes to progress in the field of Artificial Intelligence (AI), which has been enhanced by the availability of large databases and the evolution of machine learning systems. Notable examples of AI applications today range from virtual assistants, search engines and content recommendation algorithms, which are present on large online platforms, to facial recognition, geolocation, and epidemiological monitoring tools. Although the development of AI is not a new challenge, its rapid increase has inspired reflection and sparked numerous debates in the context of the knowledge society.

Use of AI can contribute greatly to strategies for sustainable human development and be, at the same time, a focus of attention by researchers, public managers, enterprises and civil society organizations. As a collaborator in our activities, AI is a powerful assistant. However, since it can directly influence decisions and deliberations, it affects various areas, from marketing policies and access to information to granting funds and aspects of public security. The potentially exponential effects of AI use have generated alarm and created legitimate concerns about possible impacts on freedom, privacy, and personal data protection. Possible widening of the digital divide must also be considered, since it can exclude those who do not have access to technology from the potential benefits of AI use.

As AI expands the human capacity to comprehend reality and allows decisions to be based on more consistent and larger volumes of data, it can be a driver of the promotion of positive results in various fields. In these complicated times, AI can be very useful in the fight against dissemination of the novel coronavirus. However, implementation of these practices must always be accompanied by an ethical dimension, in addition to the technical issues that are usually considered.

The multistakeholder model of governance led by the Brazilian Internet Steering Committee (CGI.br) can serve as an inspiration for engaging various players in society in this discussion, both for the establishment of ethical principles for the development of AI and recommendations for best practices in the creation of transparent and reliable applications. When well designed and used, AI can contribute to mitigating inequalities.

The Brazilian Network Information Center (NIC.br) maintains its purpose of carrying out projects that support the development of the Internet in the country, through resources derived from the management of “.br” domains. In addition to infrastructure initiatives, such as the implementation and operation of Internet exchange points (IX.br), management of security incidents (CERT.br), and research on network technology and operations (Ceptro.br), and those aimed at the global development of the Web (Ceweb.br), another area of effort involves surveys on the dissemination of Internet use in our society, providing important support for creating and monitoring public policies. The production of indicators on the adoption of ICT has been an essential tool for measuring the impacts of the Internet on various segments in Brazilian society.

The agenda involving AI takes on even greater relevance in monitoring the adoption of technologies by different sectors, such as health, education and culture, as well as the digital transformation of enterprises, government services and access in households, especially by children. The surveys that have been developed and carried out regularly for 15 years by the Regional Center for Studies on the Development of the Information Society (Cetic.br) represent an ongoing effort to monitor the effects of technology on economic and social aspects.

NIC.br has also adopted specific initiatives to deepen understanding of AI. Internally, a work group was created, involving its different study centers: the NICEIA – NIC Studies on AI. Furthermore, through Cetic.br, NIC.br partnered with the United Nations Educational, Scientific and Cultural Organization (Unesco) to carry out the important Regional Forum on Artificial Intelligence in Latin America and the Caribbean in São Paulo. With the support and participation of the University of São Paulo (USP), CGI.br, the Ministry of Science, Technology and Innovation (MCTI) and the Ministry of Foreign Affairs (MRE), the forum took place in December 2019¹ and represented an important landmark for the multistakeholder and humanistic approach to this debate. Another event, the Artificial Intelligence and Children Workshop, promoted by the United Nations Children’s Fund (Unicef) in March 2020², stood out as a locus of consultation involving various sectors, such as governments, enterprises, civil society and users, about the opportunities and risks presented by AI systems for our children.

Based on some already agreed-upon principles³ and evidence-based multistakeholder action, we hope our contributions can help the advancement of AI in the direction of promoting well-being, justice and equality, respecting criteria of safety, responsibility, transparency and privacy.

Demi Getschko

Brazilian Network Information Center – NIC.br

¹ More information on the forum’s website. Retrieved on March 30, 2020, from <https://unesco-regional-forum-ai.cetic.br/pt/>

² More information on Cetic.br’s website. Retrieved on March 30, 2020, from <https://cetic.br/noticia/nic-br-sedia-evento-do-unicef-sobre-inteligencia-artificial-e-uso-das-tic-por-criancas-e-adolescentes/>

³ Burle, C., & Cortiz, D. (2020). Mapeamento de princípios de inteligência artificial. São Paulo: CGI.br.

Presentation

In the current context, in which all countries are facing the COVID-19 pandemic and its social and economic consequences, the role of information and communication technologies (ICT) has become increasingly evident in different aspects of our daily lives. Digital technologies are pervasively present in all elements of life in society, habits, and the economy, which implies that their development must include the participation of all the stakeholders potentially impacted by their use.

This complex scenario has required the rapid adoption of ICT by countries in many sectors: enterprises, education, commerce, healthcare, government and others. In light of the digital transformation we are experiencing – where an economy powered by data and Artificial Intelligence (AI) driven applications are flourishing – there is a global race towards leading crucial aspects in the development of basic associated technologies, in a merge of intellectual and financial efforts that will grant the country that develops them with advantages. In emerging nations, AI-based applied technologies will play a crucial role in fostering socioeconomic development, whether by means of the appropriation of comparative advantages in the global scenario or to improve the quality and efficiency of services delivered to populations. In other words, these sets of AI-based technologies are likely to significantly increase the productivity and competently expand the economies that implement them.

Despite the benefits associated with the digital transformation, there are still many uncertainties about several aspects of its implementation. The dissemination of AI applications makes it essential to develop more in-depth studies that shed light on their scope, economic impacts, and social consequences. It is crucial to learn about possible changes in human behavior caused by the logic of algorithms, which will determine the necessary level of regulation, among many other aspects.

All these issues require the deepening of initiatives in research and technological development. Along these lines, the Ministry of Science, Technology and Innovation (MCTI) leads the creation of the Brazilian Artificial Intelligence Strategy, which will undoubtedly contribute to the identification of priority areas for the development and use of related technologies, and through which greater benefits can be obtained for the country. In this context, it is also important to emphasize the joint efforts

of the Brazilian Internet Steering Committee (CGI.br), the MCTI, the Ministry of Communications (MCom) and the São Paulo Research Foundation (FAPESP) to support the creation of applied AI research centers, which will certainly bring numerous advances in knowledge production, and consequently generate wealth and improve the entire Brazilian population's quality of life.

It is worth highlighting that constructive dialogue between government and society has been the keystone since the beginning of CGI.br, given its multisectoral nature and ongoing search for consensus among the private sector, academia, the third sector and government, each of which has a role to play in terms of the Internet governance in Brazil. Via the Brazilian Network Information Center (NIC.br), this dialogue has enabled the creation of significant initiatives for the Brazilian Internet development. These include the more than 4 million domain names registered under the “.br”, the implementation of one of the largest Internet exchange points in the world, the IX.br, the development of handbooks about safety and data protection online, measurement of the quality of the Internet provided in public schools and in society in general, and the implementation of a Web technologies study center.

Among these initiatives, the Regional Center for Studies on the Development of the Information Society (Cetic.br), which celebrates its 15th anniversary in 2020, deserves a special citation. The center plays an important role in producing statistics about the development of the information society and, in 2012, has also become a Category II Regional Center under the auspices of the United Nations Educational, Scientific and Cultural Organization (Unesco). Through CGI.br's ICT surveys, it is possible to monitor progress and underpin public policies designed to yield increasingly positive effects of ICT use in society and the economy.

Supported by the Brazilian government and organized by CGI.br and NIC.br, in December 2019 the Unesco Regional Forum on Artificial Intelligence in Latin America and the Caribbean was held. At this event, Brazil made an important contribution to the debate about the topic in the region. The discussions provided officials from developing countries with a helpful input enabling them to increase their level of readiness for AI, which will make it easier to define the roles of these nations in such technological development.

CGI.br understands that, much like the Internet, the greater the involvement of different sectors in the development of AI and 4.0 Technologies, the faster they will be implemented. Furthermore, it is essential to define minimal principles for their adoption. Digital technologies must be instruments to serve people, helping to meet human needs, and not an end in themselves. Therefore, technological, sociotechnical and institutional competences must be rapidly and concomitantly developed. Understanding these challenges should help maximize the benefits and mitigate the risks involved in this urgent and transformative journey.

Marcio Nobre Migon

Brazilian Internet Steering Committee – CGI.br



EXECUTIVE SUMMARY

—
ICT IN HEALTH
SURVEY

2019

Executive Summary

ICT in Health 2019

The ICT in Health survey investigates the access and use of information and communication technologies (ICT) in Brazilian healthcare facilities and their use by physicians and nurses. In this seventh edition, carried out in the period immediately before the dissemination of the COVID-19 pandemic in Brazil, the results outline the digital health in the country and the health system's readiness for this new context.

In terms of infrastructure, the availability of computers and Internet access in healthcare facilities has been increasing in recent years. In 2019, computer and Internet use was universal among private facilities, those located in capital cities, inpatient facilities with more than 50 beds and those that provided diagnosis and therapy services. The facilities with the lowest connectivity were public facilities (92% had computers and 85% had Internet access); and outpatient facilities and those located in non-capital cities (95% had computers and about 90% had Internet access). Regional differences

were also observed, as shown in Figure 1.

Among facilities with Internet access, the most common connections used were cable or fiber optic connections, reaching 86% of healthcare facilities in 2019. Connection via telephone lines (DSL) has gradually fallen in recent years, but was still used by 43% of the facilities. Connection via radio and satellite was present in 13% and 8% of facilities, respectively, and was more common in the North and Center-West regions.

The range of download speed of the main connection in healthcare facilities has been growing in recent years – a trend also observed in other Cetic.br/NIC.br surveys. Connections faster than 100 Mbps grew from 4% in 2018 to 11% of facilities in 2019. It is worth noting that differences in access to speeds greater than 10 Mbps occurred mainly among public (20%) and private (60%) facilities, and outpatient facilities (38%) and inpatient facilities with more than 50 beds (75%). These results show the persistence of disparities in access, especially among public facilities.

Patient information in electronic format

The use of electronic systems to record patient information is important to integrate patient care and improve the quality and effectiveness of the health system. During a pandemic, quick access to sound patient information makes it possible to monitor those in high-risk groups and aggregate data to make decisions about public health. The results for 2019 showed progress, with the presence of these systems in 82% of facilities, compared to 2018, when this percentage was 73%. Public facilities, inpatient facilities with up to 50 beds, and those in the North and Northeast region presented the lowest proportions of electronic systems, as shown in Chart 1.

IT GOVERNANCE AND INFORMATION SECURITY

Regarding information technology (IT) management and governance, in 65% of public facilities, computer technical support was performed by service providers hired by municipal health departments, while 69% of private facilities used service providers hired by the facility itself. Inpatient facilities with more than 50 beds were the only ones in which the majority (67%) had an in-house team for this service.

Regarding information security, biometric-protected access to electronic systems presented the greatest positive variation compared to the previous edition (from 8% to 16%). Inpatient facilities (more than 50 beds) and facilities that provided diagnosis and therapy services presented the best results in terms of the adoption of security tools (Chart 2). In the present edition, two new tools were included: data loss protection/prevention (DLP), present in 22% of healthcare facilities; and two-factor authentication, installed in 7% of facilities. These tools help strengthen security against information leaks: The first monitors events and system vulnerabilities; the second restricts access by unauthorized persons.

PATIENT DATA IN ELECTRONIC FORMAT

In 2019, there was an increase in the availability of patient information in electronic format. The main advances in comparison with 2018 were patient demographics (89% vs. 79%); the main reasons that led patients to medical services or appointments (64% vs. 50%); and admission, referral and discharge (56% vs. 33%).

As for the functionalities of electronic systems, emphasis goes to the increase in their availability in public facilities in recent years, mainly: listing lab test results for a specific

patient (from 17% in 2016 to 41% in 2019); listing patients on a specific medication (from 18% in 2016 to 40% in 2019); and writing medical prescriptions (29% to 51%). These increases may point to evolution in the level and complexity of the electronic systems adopted.

ABOUT A QUARTER
OF THE FACILITIES
OFFERED SERVICES
FOR BOOKING
APPOINTMENTS AND
TESTS AND VIEWING
LAB TEST RESULTS
ON THE INTERNET

ONLINE PRESENCE AND TELEHEALTH

In the current health crisis, both virtual communication and health services have played an important role in meeting recommendations for social isolation and coping with the pandemic. In 2019, private facilities (50%), inpatient facilities with more than 50 beds (51%), and those that provide diagnosis and therapy services (48%) had both websites and social

network profiles. However, more than half of public facilities (57%), about four out of ten outpatient facilities (39%), and inpatient facilities with up to 50 beds (44%) did not have websites or social network profiles.

Online services were more commonly provided by private facilities than public facilities. Booking tests (39%) and viewing lab test results (60%) on the Internet were most commonly provided by facilities that provided diagnosis and therapy services.

Regarding telehealth services, the survey investigated facilities that were authorized in the pre-pandemic period, and, as has been the case throughout the historical survey series, public facilities presented greater availability of these services. The main services provided were distance learning in health care, teleconsulting services, and distance research activities.

ICT ADOPTION IN PRIMARY HEALTHCARE UNITS

In this edition, the results for primary healthcare units (PHUs) are especially noteworthy, as they represent the point of

FIGURE 1
**USE OF COMPUTERS AND
THE INTERNET IN THE LAST 12
MONTHS (2019)**

*Total number of healthcare
facilities (%)*

North
Northeast
Center-West
South
Southeast

Computers
Internet




CHART 1
**AVAILABILITY OF AN ELECTRONIC SYSTEM
TO RECORD PATIENT INFORMATION (2019)**

*Total number of healthcare facilities that used the
Internet in the last 12 months (%)*





CHART 2
**TYPE OF INFORMATION SECURITY TOOL
USED (2019)**

*Total number of healthcare facilities that used the
Internet in the last 12 months (%)*



entry to the Brazilian Unified Health System (SUS) and play an essential role in monitoring the local population's health and in disease prevention. The 2019 results showed that 91% of these units had computers and 82% had Internet access, a result that remained stable in relation to 2018. However, there was improvement in relation to the adoption of electronic systems to record patient information, with an increase from 69% in 2018 to 78% in 2019.

How patient information is stored also varied considerably in relation to the previous year. These changes impacted the percentage of PHUs with patient data available electronically. In 2019, there was an increase in all the investigated items, as shown in Chart 4. These results may indicate a transition trend in PHUs toward digital health strategies.

There were also positive variations in relation to the percentage of PHUs with electronic functionalities available in their systems. This increase occurred in administrative functionalities such as requesting lab tests and writing medical prescriptions.

Regarding the Internet presence of PHUs, 21% had websites and 20% had accounts or profiles on social networks. About a quarter provided online services to the population, such as booking appointments and tests and viewing lab test results (Chart 5).

A higher percentage had telehealth services, with 39% offering distance learning, 25%, teliagnosis, and 30% distance research activities.

ICT ACCESS AND USE BY HEALTHCARE PROFESSIONALS

The availability of computers and the Internet for professional use has remained stable in recent years. In 2019, among physicians, 88% had access

to computers and 94% had Internet access in the facilities. It is worth highlighting that in public facilities, 23% of physicians and 14% of nurses did not have any computers available. Among physicians with computer access, 54% wrote medical prescriptions in electronic format, and 31% did so both manually and electronically.

Nonetheless, 71% signed prescriptions by hand.

Of the telehealth tools investigated, distance learning was the most available to professionals (approximately 43% for both physicians and nurses). Distance research, teleconsulting and second formative opinions were available to at least one-quarter of professionals.

Regarding the perception of professionals about the impacts of ICT use, 83% of physicians considered that there was a reduction in medication administration errors, and also improvement in quality of treatment as a whole. Among nurses, 91% perceived greater efficiency of services, and 88%, improvement in patient care as a whole.

88% OF
PHYSICIANS AND
94% OF NURSES
CONSIDERED THAT
THE USE OF ICT
HAD IMPROVED THE
EFFICIENCY OF TEAM
WORK PROCESSES


Methodology and access to data

In this edition, interviews were conducted with 2,427 managers, 1,732 physicians and 2,458 nurses who worked at selected healthcare facilities. Data collection was conducted by telephone interviews between July 2019 and February 2020. The results of the ICT in Health survey, including tables of total values and margins of error for each indicator are available on Cetic.br's website (<http://www.cetic.br>) and data visualization portal (<http://data.cetic.br/cetic>). The methodological report and the data collection report can be accessed in both the printed publication and the website.

CHART 3

TELEHEALTH SERVICES AVAILABLE (2019)

Total number of healthcare facilities that used the Internet in the last 12 months (%)



40,880

Total number of PHUs

3,581

PHUs with no computers

3,637

PHUs with no Internet access

7,270

PHUs with Internet access and with no electronic system

CHART 4

PHU BY TYPE OF PATIENT DATA ELECTRONICALLY AVAILABLE (2018 AND 2019)

Total number of healthcare facilities that used the Internet in the last 12 months (%)





CHART 5

PHU BY SERVICES OFFERED TO PATIENTS THROUGH THE INTERNET (2019)

Total number of healthcare facilities that used the Internet in the last 12 months (%)



21%

PHUs with websites

20%

PHUs with social network profiles



Access complete data from the survey

The full publication and survey results are available on the **Cetic.br** website, including the tables of proportions, totals and margins of error.



METHODOLOGICAL REPORT

ICT IN HEALTH
SURVEY

2019

Methodological Report

ICT in Health

The Brazilian Internet Steering Committee (CGI.br), through the Regional Center for Studies on the Development of the Information Society (Cetic.br), a department of the Brazilian Network Information Center (NIC.br), presents the "Methodological Report" of the Survey on the use of information and communication technologies in Brazilian healthcare facilities – ICT in Health. The study was carried out across the country, addressing subjects related to ICT penetration in healthcare facilities and its appropriation by healthcare professionals.

The data obtained through the survey seeks to contribute to the formulation of public policies specific to the health sector by generating input for public managers, healthcare facilities, healthcare professionals, academia and civil society. The survey relied on the support of international organizations such as the Organisation for Economic Co-operation and Development (OECD), Economic Commission for Latin America and the Caribbean (ECLAC) and United Nations Educational, Scientific and Cultural Organization (Unesco), as well as national entities such as the Brazilian Ministry of Health, through the Department of Informatics of the Brazilian Public Health System (Datasus) and the National Regulatory Agency for Private Health Insurance and Plans (ANS), in addition to government and civil society representatives and specialists attached to renowned universities.

The ICT in Health survey is an initiative that incorporates the model developed by the OECD for statistics in the sector. The guide created by that organization, the OECD Guide to measuring ICT in the health sector:

(...) has been developed with the aim to provide a standard reference for statisticians, analysts and policy makers in the field of health Information and Communication Technologies (ICT). The objective is to facilitate cross-country data collection, comparisons and learning on the availability and use of health ICTs (Organisation for Economic Cooperation and Development [OECD], 2015, p. 2).

Objectives of the survey

The overall goal of the ICT in Health survey was to understand the stage of ICT adoption in Brazilian healthcare facilities and their appropriation by healthcare professionals. Within this context, the study had the following specific objectives:

I. ICT penetration in healthcare facilities

- Identify the ICT infrastructure available in Brazilian healthcare facilities;
- Investigate the use of ICT-based systems and applications to support care services and management of facilities.

II. ICT appropriation by healthcare professionals

- Investigate the ICT skills of professionals and the activities carried by them with the use of ICT;
- Understand the motivations and barriers related to the adoption of ICT and its use by healthcare professionals.

Concepts and definitions

Healthcare facilities

According to the definition adopted by the National Registry of Healthcare Facilities (CNES), maintained by the Datasus, healthcare facilities can be broadly defined as all locations designated for the provision of collective or individual healthcare actions and services, regardless of their size or level of complexity. With the goal of focusing on institutions that operate with infrastructure and physical facilities devoted exclusively to healthcare activities, the survey was also based on definitions from the 2009 Survey of Medical-Sanitary Assistance (AMS) of the Brazilian Institute of Geography and Statistics (IBGE). The AMS survey encompassed all the healthcare institutions in the country that provided individual or collective, public or private, and for-profit or nonprofit health care, with a minimum level of required expertise, according to the criteria established by the Brazilian Ministry of Health for routine outpatient or inpatient care. This universe included health units, health centers, clinics and medical assistance units, emergency departments, mixed units, hospitals (including those of military organizations), complementary diagnosis and/or therapy units, dental, radiology and rehabilitation clinics and clinical analysis laboratories (Brazilian Institute of Geography and Statistics [IBGE], 2010).

Healthcare professionals

The ICT in Health survey took into account the information adopted by the CNES to identify the healthcare professionals analyzed in this study. These professionals worked in healthcare facilities providing care to patients from or not from the Unified Health System (in Portuguese, Sistema Único de Saúde - SUS). The identification of physicians and nurses was based on the Brazilian Occupational Classification (CBO) maintained by the Ministry of Labor and Employment (MTE).

Administrative jurisdiction

According to the classification given by CNES, the ICT in Health survey considered public facilities to be those administered by federal, state or municipal governments. The remaining facilities (for-profit or non-profit) were considered private.

Beds for inpatients

Specific physical facilities for receiving patients staying for a minimum of 24 hours. Day hospitals were not considered inpatient care units.

Type of facility

This classification was assigned according to a combination of characteristics of the facilities, related to the type of care provided and number of inpatient beds. The reference for this classification was the same as the one adopted by the IBGE Survey of Medical-Sanitary Assistance. Thus, four mutually exclusive groups of facilities were established:

- **Outpatient:** Facilities that do not admit patients (with no beds) and provide other types of care (emergency, outpatient, etc.);
- **Inpatient (up to 50 beds):** Facilities that admit patients and have from one to 50 beds;
- **Inpatient (more than 50 beds):** Facilities that admit patients and have 51 beds or more;
- **Diagnosis and therapy services:** Facilities that do not offer inpatient care (with no beds) and are devoted exclusively to diagnosis and therapy services, defined as units where the activities that take place help determine diagnoses and/or complement patient treatment and rehabilitation, such as labs.

Type of unit

Based on the classification of the type of facility assigned by the CNES, the ICT in Health survey uses the following classification:

- Health units;
- Health centers/basic units;
- Polyclinics;
- General hospitals;
- Specialty clinics/centers;
- Diagnosis and therapy services (isolated SADT);
- Psychosocial care centers;
- Emergency unit;
- Other types of aggregated units.

Primary healthcare unit (PHU)¹

Refers to active PHU in the National Registry of Healthcare Facilities (CNES) of the following types of facilities:

- Health units;
- Health centers/basic units;
- Mixed service units;
- Family health support centers.

TARGET POPULATION

The target population of the survey was composed of Brazilian healthcare facilities. For research purposes and surveying of the reference population, facilities registered with the CNES were considered. Thus, the scope of the survey included public and private healthcare facilities registered with the CNES that had their own registration numbers from the Brazilian Registry of Legal Entities (CNPJ) or that of a supporting entity, as well as physical facilities designated exclusively for healthcare-related activities, with at least one physician or nurse. Therefore, the following facilities were not taken into account in the survey:

- Facilities registered as natural persons;
- Isolated offices, defined as isolated spaces used for providing medical or dental care, or services of other healthcare professionals with tertiary education;
- Facilities created on a temporary basis or for campaigns;
- Mobile units (terrestrial, aerial or fluvial);
- Facilities without at least one physician or nurse on staff, except for facilities classified as SADT;
- Facilities dedicated to administration of the system, such as health secretariats, regulatory agencies and other organizations with these characteristics, currently registered with the CNES.

Each facility was treated as a conglomerate composed of professionals in administrative positions – managers responsible for providing information about the facilities – and healthcare professionals – physicians and nurses – who were the survey target population.

¹ Mobile units are not considered in the target population of the survey and were removed from the primary healthcare units, as was the case in other strata.

ANALYSIS UNIT

To achieve the objectives of the survey, healthcare facilities, and physicians and nurses (healthcare professionals) were considered to be analysis units.

DOMAINS OF INTEREST FOR ANALYSIS AND DISSEMINATION

For healthcare facility analysis units, the results are presented for domains defined according to the following variables and levels:

- **Administrative jurisdiction:** Corresponds to the classification of institutions as public or private;
- **Type of facility:** This classification is associated with four different types of facilities, based on the type of care and size, in terms of beds – outpatient, inpatient (up to 50 beds), inpatient (more than 50 beds) and diagnosis and therapy services;
- **Region:** Corresponds to the division of Brazil into macro-regions (North, Center-West, Northeast, Southeast, and South), according to IBGE criteria;
- **Location:** Refers to whether a facility is located in a capital or in non-capital cities of each federative unit;
- **Primary healthcare unit identification:** Refers to the PHU and Not a PHU classifications.

In terms of the analysis units for healthcare professionals (physicians and nurses), the following characteristics, obtained from information supplied by respondents, were added to the domains above:

- **Age group:** Refers to the age group of the professional, divided into three ranges, depending on the sample group:
 - For nurses: up to 30 years old; from 31 to 40 years old; and 41 years old or older;
 - For physicians: up to 35 years old; from 36 to 50 years old; and 51 years old or older.

Data collection instruments

INFORMATION ON THE DATA COLLECTION INSTRUMENTS

The information of interest to the survey was collected through two structured questionnaires with closed and open questions (when necessary): one was answered by administrative professionals from the facilities (preferably information technology managers) and the other by healthcare professionals (physicians and nurses). For more information about the questionnaires, see the “Data collection methodology” section in the ICT in Health “Data Collection Report”.

Sample plan

The design of the ICT in Health sample plan was based on a stratified sampling of healthcare facilities and selection with probability proportional to size (PPS). For size measurement, the square root of the total number of employees registered in the CNES was used.²

SURVEY FRAME AND SOURCES OF INFORMATION

The survey frame used for selecting the healthcare facilities was the National Registry of Healthcare Facilities maintained by the Datasus. Established by Ordinance MS/SAS No. 376, of October 3, 2000, the CNES contains the registries of all healthcare facilities (inpatient and outpatient) that compose the public and private health systems in the country. The CNES keeps databases at the local and federal levels up to date, in order to assist managers with implementing health policies. The registries are used to inform areas involving planning, regulation, evaluation, control, auditing, teaching and research (Brazilian Ministry of Health, 2006).

SAMPLE DESIGN CRITERIA

Information about type of facility, region, location, and administrative jurisdiction – variables of particular interest for disclosure of the results – was used to create the strata. Outpatient facilities are still divided according to administrative jurisdiction, primary healthcare unit and type of unit. Stratification was used to allocate the facilities and helped control expected error for each variable of interest.

SAMPLE SIZE DETERMINATION

Sample size was determined considering the optimal use of resources and the quality required to present the results. The following sections describe the sample designed to execute data collection.

SAMPLE ALLOCATION

Since one of the goals of the survey is to present the results separately for the domains defined for the variables, i.e., type of facility, region, location and administrative jurisdiction, the sample allocation was defined according to the classification of the facilities within these variables.

The survey has 156 strata for the purposes of selection, resulting from the cross-referencing of the variables: type of facility (4), region (5), location of the facility

² The square root of the total number of employees registered in the CNES was used to reduce the variability observed in this variable, making the distribution less asymmetrical and closer to normal.

(2), and administrative jurisdiction (2); for public outpatient facilities, the primary healthcare unit variable is also considered (2), whereas for private outpatient facilities, the type of unit variable is considered (9). The strata enable all the variables used to be represented in the sample, in addition to allowing analyses for the domains defined by these variables individually. However, it is not possible to reach conclusions about the categories resulting from the cross-referencing of the variables.

The sample allocation is presented in the survey's "Data Collection Report". For the purposes of dissemination, division by type of unit of the facilities among outpatient facilities will not be considered.

The sample of physicians and nurses is chosen within each of the facilities selected for the survey. No interviews with healthcare professionals (physicians and nurses) were planned for facilities dedicated to diagnosis and therapy services. Allocation depends on the size of the facility. The sample selection method is described next.

SAMPLE SELECTION

Healthcare facilities

The facilities included in the sample were selected by probability proportional to size sampling, using the square root of the number of employees in each facility according to the CNES. This meant that facilities with a larger number of employees had a higher chance of being selected. In general terms, this was done on the premise that the size measurement used is related to the variables of interest of the survey – the indicators to be collected from the questionnaire.

Healthcare professionals

To obtain an updated list of healthcare professionals, a list of each type of professional (physicians and nurses) was requested from the administrative department of the facilities in which interviews with managers were conducted. The listing procedure was different for physicians and nurses and depended on the number of these professionals in each facility.

Criteria for selecting physicians

- If up to 20 physicians worked in the healthcare facility, all were listed;
- If between 20 and 200 physicians worked in the healthcare facility, a department was randomly selected for 20 physicians to be listed;
- If over 200 physicians worked in the healthcare facility, two departments were randomly selected for 40 physicians to be listed.

For each care department selected (healthcare facilities with 20 to 200 physicians and those with over 200 physicians) listing was conducted as follows:

- If the department had 20 physicians or fewer, all were listed;
- If the department had more than 20 physicians, one shift was randomly selected to list the physicians, and:
 - If fewer than 20 physicians worked on the shift, other shifts were randomly and successively selected until reaching a list with 20 physicians or more;

- If more than 20 physicians worked on the shift, all were listed (by e-mail).

In facilities where the breakdown by departments and shifts still resulted in a list of more than 20 physicians, the respondent was requested to send the list by e-mail. From the lists sent, physicians were randomly selected to respond to the survey.

Criteria for selecting nurses

- If up to 10 nurses worked in the healthcare facility, all were listed;
- If between 10 and 50 nurses worked in the healthcare facility, a department was randomly selected for 10 nurses to be listed;
- If over 50 nurses worked in the healthcare facility, two departments were randomly selected for 20 nurses to be listed.

For each care department selected (healthcare facilities with 10 to 50 nurses and those with over 50 nurses) listing was conducted as follows:

- If the department had 10 nurses or fewer, all were listed;
- If the department had more than 10 nurses, one shift was randomly selected to list the nurses, and:
 - If fewer than 10 nurses worked on the shift, other shifts were randomly and successively selected until reaching a list with 10 nurses or more;
 - If more than 10 nurses worked on the shift, all were listed (if this list exceeded 20 nurses, the lists were received by e-mail).

In facilities where the breakdown by departments and shifts still resulted in a list of more than 10 nurses, the respondent was requested to send the list by e-mail. From the lists sent, simple random selection was used to select the nurses who were to respond to the survey.

Data processing

WEIGHTING PROCEDURES

The basic sample weight was calculated separately for each stratum and facility, based on selection with PPS.

Since the size of the facilities varied considerably; in certain strata there were some that were so large that they were automatically included in the sample, i.e., with probability equal to one. Those facilities were referred to as self-representative. Therefore, the basic weight of each facility in each stratum of the sample was determined by the Formula 1.

FORMULA 1

$$w_{ih} = \begin{cases} \frac{M_h}{n_h \times m_{ih}}, & \text{if the number of employees per facility is less than the "size measurement for the stratum"} \\ 1, & \text{otherwise} \end{cases}$$

w_{ih} is the basic weight, equal to the inverse of the probability of selection, for facility i in stratum h
 M_h is the sum of the square root of the total number of employees in h (except for self-representative facilities)
 n_h is the total sample of facilities, excluding self-representative ones, in stratum h
 m_{ih} is the square root of the total number of employees from facility i in stratum h

w_{ih} is the basic weight associated with each of the facilities selected. Of these, some did not respond to the survey. An adjustment for nonresponse was made to weights of the responding facilities. The adjustment for nonresponse is given by the Formula 2.

FORMULA 2

$$w_{ih}^* = \begin{cases} w_{ih} \times \frac{S_h^s}{S_h^r}, & \text{if the facility was not self representative} \\ \frac{n_{ph}}{n_{ph}^e}, & \text{otherwise} \end{cases}$$

w_{ih}^* is the adjusted weight for nonresponse for facility i in stratum h
 w_{ih} is the basic weight of facility i in stratum h
 S_h^s is the sum of the weights of selected facilities in stratum h
 S_h^r is the sum of the weights of responding facilities in stratum h
 n_{ph} is the total number of self-representative facilities in stratum h
 n_{ph}^e is the total number of responding self-representative facilities in stratum h

Finally, the adjusted weight for nonresponse underwent post-stratification for the stratification variables, the results (region, location, type of facility, and administrative jurisdiction) of which were also presented. Therefore, based on the variables used for selection, the total number of facilities from the sample agreed with the total number of facilities in the registry. Post-stratification was done by multiplying the adjusted weight for nonresponse in each stratum w_{ih}^* by a factor that adjusted the total of the stratum (sum of adjusted weights for nonresponse) to the total of the population.

Weighting the physicians

The target physician population of the survey was defined as:

- Non-resident physicians on staff in outpatient healthcare facilities;
- Non-resident physicians on staff in inpatient healthcare facilities, regardless of the number of beds.

Diagnosis and therapy service facilities were excluded from the target population.

The first factor considered in the weighting of physicians was the final weight of responding facilities in the survey. Of the responding facilities in the survey (adjusted for nonresponse and post-stratification), some did not provide physician response. Nonresponse among this target audience was higher than that observed for facilities. Thus, the adjustment for nonresponse for facilities in which interviews with physicians took place was done by fitting a logistic model to predict the response probability of physicians in each facility. Using known variables from the population of facilities, the probability of interviewing physicians was estimated.

This model starts based on the following variables: type of facility, region, location of the facility, administrative jurisdiction, size of the facility (in ranges) and respondent's job position. The objective of the model is to correctly classify respondents and nonrespondents in at least 60% of the facilities. The result of the model represents the estimated response probability for each of the facilities. Thus, adjustment for nonresponse was obtained by the Formula 3.

FORMULA 3

$$m_{ih} = w_{ih}^* \times \frac{1}{p_r}$$

m_{ih} is the adjusted weight for nonresponse for interviews with physicians in facility i in stratum h

w_{ih}^* is the final weight of facility i in stratum h

p_r is the probability of the facility being a respondent according to the logistic model for adjustment for nonresponse

The second factor used to obtain the weight for responding physicians referred to the probability of the physician being selected for the interview at the facility. The procedure for selecting days/shifts prevented the selection of physicians on weekends (no data collection took place on weekends). For this reason, an ad hoc selection probability was calculated, based on the assumption that responding day/shift physicians were randomly selected from the total group of physicians. Thus, the weight of physicians in the facility was obtained by the Formula 4.

FORMULA 4

$$m_{ih}^e = \frac{N_{ih}^m}{n_{ihr}^m}$$

m_{ih}^e is the adjusted weight for nonresponse for interviews with physicians in facility i in stratum h

N_{ih}^m is the total number of physicians listed by facility i in stratum h

n_{ihr}^m is the total number of responding physicians in facility i in stratum h

The final weight for physicians (m_{ih}^+) was obtained by multiplying the two factors:

$$m_{ih}^+ = m_{ih} \times m_{ih}^e$$

Weighting the nurses

The target population of nurses in the survey was defined by professionals who worked in the healthcare facilities, whether outpatient or inpatient (regardless of the number of beds). Diagnosis and therapy service facilities were excluded from the target population.

The first factor considered in the weighting of nurses was the final weight of responding facilities in the survey. Of the responding facilities in the survey (adjusted for nonresponse and post-stratification), some did not have nurse response. The nonresponse rate among this group was higher than that observed among facilities. Thus, a logistic model for facilities in which interviews with nurses took place was done by fitting a logistic model to predict the response probability of nurses in each facility. Using known variables from the population of facilities, the probability of interviewing nurses was estimated.

This model starts based on the following variables: type of facility, region, location of facility, and administrative jurisdiction (in ranges) and respondent's job position.

The objective of the model is to correctly classify respondents and nonrespondents in at least 60% of the facilities. The result of the model represents the estimated response probability for each of the facilities. Thus, adjustment for nonresponse was obtained by the Formula 5.

FORMULA 5

$$e_{ih} = w_{ih}^+ \times \frac{1}{p_r}$$

e_{ih} is the adjusted weight for nonresponse for interviews with nurses in facility i in stratum h

w_{ih}^+ is the final weight of facility i in stratum h

p_r is the probability of the facility being a respondent according to the logistic model for adjustment for nonresponse

The second factor used to obtain the weight for responding nurses referred to the probability of the nurse being selected for the interview at the facility. Since the same procedure was adopted for physicians and nurses, the same weighting method was used. The weight of nurses in the facility was obtained by the Formula 6.

FORMULA 6

$$e_{ih}^e = \frac{N_{ih}^e}{n_{ihr}^e}$$

e_{ih}^e is the adjusted weight for nonresponse for interviews with nurses in facility i in stratum h

N_{ih}^e is the total number of nurses listed by facility i in stratum h

n_{ihr}^e is the total number of responding nurses in facility i in stratum h

The final weight for nurses (e_{ih}^*) was obtained by multiplying the two factors: $e_{ih}^* = e_{ih}^c \times e_{ih}^e$

CALIBRATION OF THE PHYSICIANS AND NURSES WEIGHTS

The weights of the physicians and nurses interviews are calibrated in order to reflect known population totals, obtained from the CNES database. This procedure, in addition to the adjustment for nonresponse, seeks to correct variability associated with nonresponse of the population of healthcare professionals.

The variables considered for calibration of healthcare professionals (physicians and nurses) are those used for stratification: type of facility, region, location, and administrative jurisdiction.

The calibration of the weights was implemented using the SPSS software.

SAMPLING ERROR

The measurements or estimates of sampling error in the indicators of the ICT in Health survey took into consideration in its calculations the sample plan by strata used in the survey.

The ultimate cluster method was used to estimate variances for total estimators in multi-stage sample plans. Proposed by Hansen, Hurwitz and Madow (1953), this method considers only the variation between information available at the level of primary sample units (PSU) and assumes that these have been selected with replacement.

Based on this method, it is possible to consider stratification and selection with unequal probabilities, for both primary sample units and other sample units. The assumptions that permit the application of this method are that unbiased estimators are available for the totals of the variables of interest for each of the selected ultimate clusters, and that at least two of these estimators are selected in each stratum (if the sample was stratified in the first stage).

This method provides the basis for several statistical packages that specialize in calculating variances, based on the sample plan. Therefore, based on the estimated variances, the option was chosen to publish the sample errors expressed by the margin of error. For publication, the margins of error were calculated for a confidence level of 95%. This means that if the survey were to be repeated many times, 19 out of 20 times the range could contain the actual population value. Other measures derived from this variability estimate are commonly presented, such as standard error, coefficient of variation and confidence interval.

Margins of error were calculated by multiplying the standard error (square root of the variance) by 1.96 (sample distribution value, which corresponds to the chosen significance level of 95%). These calculations were done for each variable in all the tables. Hence, all indicator tables had margins of error related to each estimate presented in each cell of the table.

Data dissemination

The results of this survey are presented according to the domains of analysis: administrative jurisdiction, region, type of facility, PHU identification and location, for information about the healthcare facility, in addition to the age group variable for information on the healthcare professionals.

Rounding made it so that in some results, the sum of the partial categories differed from 100% for single-answer questions. The sum of frequencies on multiple-answer questions is usually different from 100%. It is worth noting that, in cases with no response to the item, a hyphen was used. Since the results are presented without decimal places, a cell's content is zero whenever an answer was given to that item, but the result for this cell is greater than zero and smaller than one.

The data and the results for the ICT in Health survey are published in book format and are made available on the Cetic.br website (www.cetic.br) and data visualization portal (<http://data.cetic.br/cetic>). The tables of proportions, totals and margins of errors calculated for each indicator are available for download in Portuguese, English and Spanish. More information about the research documentation, metadata and microdata bases is available on the Cetic.br microdata page (<https://cetic.br/microdados/>).

References

Brazilian Institute of Geography and Statistics – IBGE. (2010). *Pesquisa Assistência Médico-Sanitária 2009*. Rio de Janeiro: IBGE. Retrieved on September 21, 2020, from <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=283176>

Brazilian Ministry of Health. (2000). *Cadastro Nacional dos Estabelecimentos de Saúde*. Established by Ordinance MS/SAS 376, of October 2, 2000. Retrieved on April 20, 2015, from <http://cnes.datasus.gov.br/>

Brazilian Ministry of Health. (2006). *Manual do Cadastro Nacional dos Estabelecimentos de Saúde (CNES) – Versão 2*. Retrieved on September 21, 2020, from <http://cnes.datasus.gov.br/pages/downloads/documentacao.jsp>

Hansen, M. H., Hurwitz, W. N., & Madow, W. G. (1953). *Sample survey methods and theory*. Nova Iorque: Wiley.

Organisation for Economic Cooperation and Development – OECD. (2015). *Draft OECD guide to measuring ICTs in the health sector*. Retrieved on September 21, 2020, from <https://www.oecd.org/health/health-systems/Draft-oecd-guide-to-measuring-icts-in-the-health-sector.pdf>

DATA COLLECTION REPORT

ICT IN HEALTH
SURVEY

2019

Data Collection Report

ICT in Health 2019

The Brazilian Internet Steering Committee (CGI.br), through the Regional Center for Studies on the Development of the Information Society (Cetic.br), of the Brazilian Network Information Center (NIC.br), presents the “Data Collection Report” of the 2019 ICT in Health survey. The objective of this report is to provide information about specific characteristics of the 2019 survey, including changes made to data collection instruments, sample allocation, and response rates.

The complete survey methodology, including the objectives, main concepts, definitions, and characteristics of the sampling plan, are described in the “Methodological Report”, available in this publication.

Data collection instruments

INFORMATION ON THE DATA COLLECTION INSTRUMENTS

The data was collected through two structured questionnaires, one answered by administrative professionals from the facilities (preferably information technology managers) and the other by healthcare professionals (physicians and nurses). Information on the healthcare facilities was obtained from professionals at the managerial level, whereas physicians and nurses answered questions about their own work routines as healthcare professionals, according to the definitions set forth in the “Concepts and definitions” section.

The questionnaire about the healthcare facilities contained information regarding ICT infrastructure, information technology (IT) management, electronic health records, information exchange, online services provided to patients, and telehealth. The questionnaire targeting professionals investigated their profiles, in addition to ICT access, use and appropriation.

CHANGES IN THE DATA COLLECTION INSTRUMENTS

Based on the results of the interviews conducted during the pretests, changes were made to the survey questionnaire. The main objective of the changes was to adapt the questionnaire to standards under discussion in international forums for collection of data on the use of information and communication technologies in the health sector.

Other modifications were made to test new items relevant to understanding ICT access and use in the sector, and to enhance the collection of information.

The main changes in the questionnaire about the healthcare facilities were as follows:

Module B – ICT Infrastructure in the facility:

- Inclusion of a new indicator that investigates information security training of professionals in healthcare facilities.
- Inclusion of two new items on the use of information security tools in healthcare facilities: two-factor authentication and data loss prevention/protection (DLP).

COGNITIVE INTERVIEWS

Cognitive interviews were conducted to help change the ICT in Health 2019 survey questionnaires. Based on the results of the interviews, no changes were made to the main context of the survey questions answered by the managers of healthcare facilities, but there were changes to further clarify already existing statements and question items, such as the introduction of examples and specifications in the statements.

More significant changes were made to the collection instrument for healthcare professionals (physicians and nurses). These changes were in reference to questions about telehealth and taking health informatics courses. During the interviews, it was noted that the respondents had difficulties with the formulation that involved the presentation of the concepts of these topics. Consequently, these indicators were more thoroughly reformulated and, in both cases, the items in the question statements were changed, in order to better specify the concepts.

PRETESTS

Nine interviews were conducted with general or IT managers of healthcare facilities between July 22 and 26, 2019, along with twelve interviews with healthcare professionals (six physicians and six nurses), between August 27 and September 02, 2019 in different types of healthcare facilities. The aim of this distribution was to test the adequacy and validity of the constructed questions and indicators and measure the time required to administer the questionnaires.

INTERVIEWER TRAINING

The interviews were conducted by a team of trained and supervised interviewers. They underwent basic research training; organizational training; ongoing improvement training; and refresher training. They also underwent specific training for the 2019

ICT in Health survey, which included how to approach the responding audience, and information about the data collection instrument, procedures and situations.

The data collection team also had access to the survey's instruction manual, which contains a description of all the necessary procedures to collect data and details about the survey objectives and methodology, ensuring the standardization and quality of the work.

Data collection for managers of healthcare facilities was performed by 42 interviewers, two supervisors and two assistants. Data collection for healthcare professionals was carried out by 52 interviewers, two supervisors and two assistants.

Sample allocation

Table 1 presents the sample allocation of healthcare facilities considered by the survey.

TABLE 1

SAMPLE ALLOCATION OF HEALTHCARE FACILITIES BY REGION, LOCATION, ADMINISTRATIVE JURISDICTION AND TYPE OF FACILITY

		Sample
Region	North	653
	Northeast	879
	Southeast	880
	South	727
	Center-West	688
Location	Capital cities	1 290
	Non-capital cities	2 537
Administrative jurisdiction	Public	1 834
	Private	1 993
Type of facility	Outpatient	1 281
	Inpatient (up to 50 beds)	941
	Inpatient (more than 50 beds)	998
	Diagnosis and therapy services	607

Data collection procedures

DATA COLLECTION METHOD

The aim was to interview the main manager or a manager who was familiar with the organization as a whole, including both its administrative aspects and ICT infrastructure. In the 2019 ICT in Health survey, preference was given to IT managers,

who answered questions about the healthcare facilities. Healthcare professionals, nonresident physicians, and nurses were selected as described in the “Sample selection” section of the “Methodological Report”.

Data collection was conducted using the computer-assisted telephone interviewing (CATI) technique, with both administrative professionals and healthcare professionals. Interviews to administer the questionnaires lasted an average of 36 minutes for managers and 20 minutes for physicians and nurses.

DATA COLLECTION PERIOD

Data for the manager interview phase of the 2019 ICT in Health survey was collected between August and November 2019; for the phase with healthcare professionals, it was collected between September 2019 and February 2020. The interviews with managers were carried out between 8 AM and 7 PM Brasilia time (UTC-3). Interviews with physicians and nurses were carried out between 8 AM and 7 PM and were scheduled in advance.

PROCEDURES AND CONTROLS

An automated system was established that enabled measuring and controlling the effort expended to obtain the interviews. It involved the treatment of situations identified during the information collection.

Prior to the fieldwork, the list of phone numbers to be used to contact the facilities was reviewed and checked. The team tried contacting all the facilities selected in the sample and, whenever there was an incorrect or outdated number, they looked for a new contact number for the facility.

After the list was revised, the following procedures were carried out:

- Contacting the facilities and identifying the respondents. Whenever possible, the team sought to interview the managers responsible for IT departments or, if these professionals did not exist, the main managers responsible for the facilities. If it was impossible to interview the main persons responsible, managers capable of answering questions about general aspects of the facilities, such as administrative information, ICT infrastructure and human resources, were identified. Professionals who did not hold management, coordination or supervisory positions were not considered.
- Scheduling and conducting the interviews with the managerial professionals. The managers were informed at the beginning of the interviews that the process involved two stages: one with managers and another with physicians and nurses, who would also be interviewed.

After interviewing the managers, if the facilities had physicians and/or nurses and were outpatient facilities, inpatient facilities with up to 50 beds, or inpatient facilities with over 50 beds, the next stage involved obtaining lists of professionals. If the managers indicated other professionals to provide the lists (which normally

come from administrative departments), these professionals were contacted to request lists of professionals (physicians and nurses) in the facilities or lists drawn from the shifts and/or departments selected (as explained in the “Sample selection” section of the “Methodological Report”). Each list had to contain names and telephone numbers that uniquely identified the professionals. After the lists were obtained, the professionals were selected, if necessary, according to the instructions provided in the “Methodological Report” and then contacted. If it was not necessary to select professionals, all those on the list were entered into the system. Thus, the final step of the field work consisted of:

- Scheduling and conducting the interviews with physicians and nurses. All the professionals selected from the sample were contacted for interviews.

For both managers and healthcare professionals, refusal to participate or problems contacting identified or selected respondents prevented some interviews from being carried out.

DATA COLLECTION RESULTS

In the 2019 ICT in Health survey, interviews were conducted in 2,427 healthcare facilities, reaching 63% of the planned sample of 3,827 facilities. Of these, 2,027 were eligible to contribute to the physician sample, and at least one interview with physicians was performed in 724 facilities, resulting in 1,732 interviews completed with physicians.

Similarly, 1,934 facilities were eligible to contribute to the nurse sample; from this number, at least one interview was conducted with nurses in 993 facilities, resulting in a sample of 2,458 interviews completed with nurses. The rate of response for facilities, physicians, and nurses by stratification variable is presented in Tables 2, 3, and 4.

TABLE 2

RATE OF RESPONSE OF FACILITIES BY REGION, LOCATION, ADMINISTRATIVE JURISDICTION AND TYPE OF FACILITY

		Rate of response
Region	North	58%
	Northeast	58%
	Southeast	62%
	South	75%
	Center-West	65%
Location	Capital cities	54%
	Non-capital cities	68%
Administrative jurisdiction	Public	73%
	Private	54%
Type of facility	Outpatient	64%
	Inpatient (up to 50 beds)	65%
	Inpatient (more than 50 beds)	69%
	Diagnosis and therapy services	49%

TABLE 3

RATE OF RESPONSE OF FACILITIES FOR NURSES BY REGION, LOCATION, ADMINISTRATIVE JURISDICTION, AND TYPE OF FACILITY

		Eligible	Rate of response
Region	North	310	52%
	Northeast	417	51%
	Southeast	410	45%
	South	432	57%
	Center-West	365	52%
Location	Capital cities	501	34%
	Non-capital cities	1 433	58%
Administrative jurisdiction	Public	1 224	61%
	Private	710	35%
Type of facility	Outpatient	724	63%
	Inpatient (up to 50 beds)	597	54%
	Inpatient (more than 50 beds)	613	35%
	Diagnosis and therapy services	–	–

TABLE 4

RATE OF RESPONSE OF FACILITIES FOR PHYSICIANS BY REGION, LOCATION, ADMINISTRATIVE JURISDICTION AND TYPE OF FACILITY

		Eligible	Rate of response
Region	North	329	35%
	Northeast	432	31%
	Southeast	428	30%
	South	451	43%
	Center-West	387	40%
Location	Capital cities	543	24%
	Non-capital cities	1 484	40%
Administrative jurisdiction	Public	1 233	42%
	Private	794	26%
Type of facility	Outpatient	789	41%
	Inpatient (up to 50 beds)	604	38%
	Inpatient (more than 50 beds)	634	26%
	Diagnosis and therapy services	–	–

Data processing

WEIGHTING THE PHYSICIANS

The target physician population of the survey was defined as:

- Non-resident physicians in outpatient healthcare facilities;
- Non-resident physicians in inpatient healthcare facilities, regardless of the number of beds.

Diagnosis and therapy service facilities were excluded from the target population.

The first factor considered in the weighting of physicians was the final weight of responding facilities in the survey. Of the 2,427 responding facilities, 2,027 said they had at least one non-resident physician and were not a facility for diagnosis and therapy services. From that number, interviews with physicians were conducted in 724 facilities.

The adjustment for nonresponse for facilities was done by fitting a logistic model to predict the response probability of each facility. Five variables proved to be decisive in fitting the model:

- Region;
- Administrative jurisdiction;
- Number of physicians working at the facilities in categories;
- Type of facility;
- Location.

The logistic model correctly classified 64.9% of the total number of records.

WEIGHTING THE NURSES

The target population of nurses in the survey was defined as professionals who worked in the healthcare facilities, whether outpatient or inpatient (regardless of the number of beds). Diagnosis and therapy service facilities were excluded from the target population.

The first factor considered in the weighting of nurses was the final weight of responding facilities in the survey. Of the 2,427 responding facilities in the survey, 1,934 said they had at least one nurse and were not a facility for diagnosis and therapy services. From that number, interviews with nurses were conducted in 993 facilities. For the adjustment for nonresponse of the facilities, the same method used for physicians was adopted – a logistic model.

Five variables proved to be decisive in fitting the model:

- Region;
- Administrative jurisdiction;
- Number of nurses working in the facility in categories;
- Type of facility;
- Location.

The logistic model correctly classified 64.1% of the total number of records.

ANALYSIS OF RESULTS

ICT IN HEALTH
SURVEY

2019

Analysis of Results

ICT in Health 2019

In early 2020, the world became familiar with COVID-19, an acute respiratory disease caused by the new coronavirus, SARS-CoV-2. First identified in December 2019 in the city of Wuhan, in Central China, its exponential growth led the World Health Organization (WHO) to declare, in January, that the outbreak of the new coronavirus should be considered a Public Health Emergency of International Concern (PHEIC), the organization's highest level of alert. In March, COVID-19 was characterized as a pandemic (World Health Organization [WHO], 2020). In August of the same year, COVID-19 was already present in 188 countries¹, giving rise to a health and humanitarian crisis of unprecedented proportions, which led to the rapid growth of deaths and pressure on healthcare systems around the world.

Given this pandemic context, the adoption of information and communication technologies (ICT) has become even more essential. The use and quality of electronic systems to record patient information has increased the sharing and immediate access of this data, enabling responsible bodies to make decisions and coordinate actions to combat the pandemic (Pan American Health Organization [PAHO], 2020a).

The availability of data allows “to understand more quickly the behavior of the pandemic in a given population; so that adequate and timely containment and/or mitigation interventions can be made” (PAHO, 2020a, p. 2). It is important to observe that the availability of data is directly linked to its collection and recording, since only complete, safe and quality records allow for analyses that can support decision-making in health, with the analysis of trends and patterns of disease incidence. In the case of COVID-19, access to data helps to understand the specific characteristics of the groups most affected by the disease and the most vulnerable strata of populations, which allows planning the allocation of resources and strategies aimed at containing the proliferation of the disease (PAHO, 2020b).

¹ More information available on John Hopkins' COVID-19 statistical data dashboard. Retrieved August 15, 2020, from <https://coronavirus.jhu.edu/map.html>

The use of electronic systems and the quality of records also point to the importance of monitoring digital health and the degree of maturity that countries can achieve in information exchange. In Brazil, the data from previous editions of the ICT in Health survey have shown that digital health has maintained a growth trend through increased adoption of ICT in healthcare facilities and adaptation to new modes of service, care and monitoring of citizens' health. With the onset of the COVID-19 pandemic, timely access to safe and accurate information has become even more relevant in a dynamic global health decision-making scenario. The use of ICT, in this context, has been essential to reconcile agility, accuracy, and reliability in the sharing of information between the public and private networks of the Brazilian health system, and between federative units. Thus, it is urgent that governments, at all levels, rethink and expand the role of ICT in health. These tools have proven to be an inherent part of the prevention of this and other possible new health crises, whether caused by unknown types of viruses or by neglected diseases.

Numerous ICT-based actions have been developed to prevent and monitor the spread of the pandemic in the country. The high dissemination potential of the virus, the ease of contagion in indoor spaces, and the need to avoid mass demands for health care – preventing patients with other diseases from running the risk of becoming infected with the new coronavirus – have made telehealth a fundamental care strategy, enabling citizens to get access to adequate and qualified information about how to proceed (Dorsey & Topol, 2020). In addition, in cases of individuals with high anxiety levels and/or mild or moderate COVID-19 symptoms, online care represents an important alternative to prevent contagion and facilitate social isolation (Greenhalgh, Wherton, Shaw, & Morrison, 2020). With a wide array of digital technologies and multiple and diverse applications, telehealth has shown great potential to be used as a tool to cope with the COVID-19 pandemic (Caetano et al., 2020).

In this state of emergency, the Brazilian federal government enacted Law No. 13989 of April 15, 2020, authorizing the use of telemedicine during the pandemic and allowing doctors to care for their patients through virtual media. This measure also allows healthcare professionals who are at higher risk for contracting the disease – those with preexisting conditions, pregnant women, and employees over 60 years old – to continue providing care online. At a time when many professionals have been transferred to front line care of patients with COVID-19, and others are away on leave because they have been contaminated, and given the difficulty of expanding the health workforce within a short time frame to meet the growth of this new demand, the use of technologies and telemedicine have made it so that other patients have not been left without care (Portnoy, Waller, & Elliot, 2020). It is noteworthy that in Brazil the use of telemedicine still faces barriers to its expansion due to gaps and inequalities in ICT access by healthcare facilities and citizens.

Other actions in the public and private spheres have included the provision of applications that help citizens self-assess their symptoms, reducing the demand for in-person care in the health system – as is the case with the Coronavirus SUS app (Ministry of Health [MS], 2020a). Resources such as Artificial Intelligence, machine learning techniques, and predictive algorithms have been used to monitor recorded cases to trace the spread of the virus and actively search for people possibly exposed to it. They have also been used to predict the spread of the disease, support diagnosis and treatment, manage hospital beds and supplies, and develop new drugs and vaccines (Tunes, 2020).

The ICT in Health 2019 survey was carried out immediately before the dissemination of the pandemic in Brazil, from – July 2019 to February 2020. It presents data that help map out the scenario of ICT adoption in healthcare facilities and their appropriation by healthcare professionals. The study presents a diagnosis of the digital health situation in the country through data on the ICT infrastructure in healthcare facilities, the availability of health systems to record information about patients and their levels of complexity, and indicators on security and privacy of clinical data and use of telehealth.

In this edition, the Analysis of Results is divided into the following sections:

- ICT infrastructure and use in healthcare facilities;
- IT management and governance;
- Electronic health records and information exchange;
- Online services provided to patients and telehealth;
- ICT adoption in primary healthcare units;
- ICT access and use by healthcare professionals;
- Final considerations: agenda for public policies.

ICT infrastructure and management in healthcare facilities

Computers and Internet access must be present in all Brazilian healthcare facilities if digital health is to effectively grow in the country. Since 2013, the ICT in Health survey has shown a growth trend in the presence of computers and the Internet in Brazilian healthcare facilities; among inpatient institutions and those that provide diagnosis and therapy support services, this presence was universal in 2019. Among outpatient facilities, 95% had computers and 91% had Internet access. This result indicates a deficit: about 4,400 facilities did not have computers and 8,200 did not have Internet access.

Disparities in access to ICT infrastructure are striking between administrative jurisdictions and the country's geographic regions. According to Table 1, an estimated 50,000 public facilities (92%) had computers and 46,300 (85%) had Internet access, while in private facilities access was universal. Considering regional differences in access to these technologies, as identified in other Cetic.br surveys², the ICT in Health 2019 survey showed that, while 99% of facilities in the Southeast region used computers and 98% had access to the Internet, in the North, this proportion fell to 92% of facilities using computers and 82% with Internet access, a figure close to that of the Northeast region, in which 90% used computers and 83% had access to the Internet. In the latter case, the data in the table below indicate that of a total of 30,700 health facilities located in the Northeast, 2,800 did not have computers and 4,900 did not have access to the Internet.

² In 2019, the Northeast had the lowest proportion of households connected to the Internet (65%), while the Southeast was the highest (75%). The Center-West had 70%; the North 72%; and the South 73%.

TABLE 1

HEALTHCARE FACILITIES THAT USED COMPUTERS AND THE INTERNET (2019)*Total number of healthcare facilities (%)*

Type of facility		Used computers		Used the Internet	
		Yes	No	Yes	No
TOTAL		105 157	4 483	101 400	8 464
ADMINISTRATIVE JURISDICTION	Public	50 063	4 342	46 306	8 099
	Private	55 094	141	55 094	365
REGION	North	6 608	562	5 884	1 286
	Northeast	27 880	2 835	25 776	5 163
	Southeast	43 315	461	42 780	996
	South	18 161	398	17 956	603
	Center-West	9 194	226	9 004	416
TYPE OF FACILITY	Outpatient	83 837	4 420	80 087	8 394
	Inpatient (up to 50 beds)	4 798	39	4 791	47
	Inpatient (more than 50 beds)	2 792	0	2 792	0
	Diagnosis and therapy services	13 730	24	13 730	24
LOCATION	Capital cities	24 368	78	24 294	152
	Non-capital cities	80 790	4 404	77 106	8 311

Regarding types of Internet connections used by facilities, the survey's historical series has shown growing use of connections via cable or optical fiber: from 65% in 2015 to 86% in 2019. Thus, this type of connection – a technology that allows higher access speed with lower latency – has become the most used for Internet access among all types of healthcare facilities. As shown in Chart 1, since 2015 there has been an increase in the proportion of facilities that accessed the Internet via cable or optical fiber, while DSL connection has presented a downward trend since 2018, reaching 43% in 2019.

Among geographic regions, the greatest increase in cable or optical fiber connections was observed in the Northeast: from 57% in 2015 to 91% in 2019. In the South, this type of connection grew from 58% to 82%, in the Southeast, 74% to 86%, and in the Center-West, 58% to 77% of healthcare facilities. In the North, this proportion remained stable, with about 73% of facilities using cable or optical fiber connections in the same period.

Despite this progress, public health facilities (80%) and those located in non-capital cities (84%) presented a lower proportion of cable or optical fiber connection than private facilities (90%) and those located in capital cities (92%). Other types of

broadband connections were also more common among private facilities and those located in capital cities, except for radio connections, which were still more present among public facilities (18%) and those in non-capital cities (15%).


There was a higher proportion of facilities that used mobile connections via 3G or 4G modems or chips, reaching 39% of healthcare facilities in 2019, which could be associated with a trend toward increasing availability of mobile devices in healthcare facilities, especially in primary healthcare units (PHUs). The data indicates that this type of connection is complementary to other types, because less than 2% of facilities had exclusively mobile connections.

Expansion in the use of mobile connections may be associated with an increase in apps made available by the Informatics Department of the Brazilian Unified Health System (Datasus). Some of these apps include MedSus, which presents a list of medications indicated by SUS; modules for managers, such as e-SUS Gestor and the e-Gestor AB for primary care; and an app for users – Meu digiSUS – which provides personal and clinical information present on the National Registry of SUS Users, on the Citizen's Health Portal and on the National Registry of Healthcare Facilities (CNES).³

CHART 1

HEALTHCARE FACILITIES BY TYPE OF INTERNET CONNECTION (2019)

Total number of healthcare facilities that used the Internet in the last 12 months (%)



³ More information on the Datasus website. Retrieved on August 15, 2020, from <https://datasus.saude.gov.br/wp-content/uploads/2019/08/Catalogo-de-Produtos-DATASUS.pdf>

The maximum download speed of the main connection of healthcare facilities has also increased in recent years. In 2019, 32% had contracted connections of up to 10 Mbps, a decrease of four percentage points compared to 2018. The percentage of those with speeds above 100 Mbps went from 4% in 2018 to 11% in 2019. This same trend was observed in other public and private institutions. In 2019, 17% of Brazilian companies had connections with speeds greater than 100 Mbps – an increase of 12 percentage points compared to 2015 (Brazilian Internet Steering Committee [CGI.br], 2020a). Among urban schools, 17% had connections of 51 Mbps or more in 2019, 15 percentage points more than in 2015 (CGI.br, 2020b).


Despite advances in the speed of connection in healthcare facilities, there were disparities according to administrative jurisdiction and type of facility, and the highest speeds were concentrated in private facilities and inpatient facilities with more than 50 beds, as shown in Chart 2. Regarding public facilities, almost half of the managers (46%) did not know the answer to this question, because the service is usually hired by municipal health departments, especially in the case of PHUs, which made up the group of outpatient facilities.

Among inpatient facilities with more than 50 beds (56%) and those that offer diagnosis and therapy services (41%), connections between 10 and 100 Mbps were more frequent, compared to the total of Brazilian facilities (30%). Despite these differences, there was a significant increase in the proportion of outpatient facilities and inpatient facilities with up to 50 beds that contracted connections with speeds above 100 Mbps. In inpatient facilities with up to 50 beds, this percentage went from 5% to 11% between 2018 and 2019. In outpatient facilities, this percentage went from 3% to 10%.

CHART 2

HEALTHCARE FACILITIES BY RANGE OF DOWNLOAD SPEED OF THE MAIN CONNECTION (2019)

Total number of healthcare facilities that used the Internet in the last 12 months (%)



Approximately half of managers said that they agreed that their information technology (IT) equipment was new and up-to-date (52%), and that the Internet connection was adequate for the needs of the facility (50%). This perception has improved in recent years, but it was still more frequent among managers of private facilities: in 2019, 36% of managers of public facilities and 68% of private ones agreed that the equipment was new and up to date, an increase of five and ten percentage points, respectively, compared to the previous year. As for the Internet connection, 31% of managers of public facilities and 67% of private ones said that it was adequate for the needs of the facility. In this regard, perceptions only improved among public managers, with an increase of five percentage points compared to 2018.

This difference in perceptions was also observed between managers of facilities located in non-capital cities and capital cities: While 47% of managers of facilities in non-capital cities said that the equipment was new and up-to-date, 68% of managers of facilities in capital cities agreed with this statement, representing an increase of seven and nine percentage points, respectively, compared with 2018. In terms of Internet connection, 47% of managers in non-capital cities and 59% of managers in capital cities said that it met the demands of the facilities, with no significant variation compared to the previous year.

IT management and governance

The presence of IT areas or departments in healthcare facilities, coupled with qualified and dedicated professionals to manage ICT resources, is important to create strategies that aim at improving the development, adaptation, and appropriation of ICT in healthcare facilities and by professionals. Structured IT governance has a strategic role in the development of processes guided by facility objectives, based on changes in technology processes and delivery. However, it is still a challenge for many managers to adopt a broader view of the role of IT, since it is not the organization's core activity (Santos & Terra, 2018). It is essential, thus, that the use of ICT be understood as a strategic resource and not as a service.

The ICT in Health 2019 survey indicates stability in the proportion of healthcare facilities that had IT areas (27% in 2019 and 25% in 2018). It can be inferred that in organizations, the IT area is still seen as a resource for providing services and guaranteeing infrastructure to reach digital maturity. The presence of these departments was uneven between administrative jurisdictions and different types of Brazilian healthcare facilities. A lower percentage of public facilities (14%) had IT departments compared to private facilities (38%). While most inpatient facilities with more than 50 beds had IT areas or departments (80%), this proportion was much lower among the other facilities, with the lowest percentage observed among outpatient facilities (23%).

Among healthcare facilities that had IT areas or departments, most had between one and three employed persons in this area (76%), a percentage that did not vary significantly in terms of administrative jurisdiction. Among those that reported having more employed persons in IT areas or departments, 22% of public facilities and 14% of private facilities said they had between four and ten employed persons, and only 2% of public and 9% of private facilities indicated having more than ten employed persons working in this area.


Only two out of ten of facilities with IT departments had employed persons with health degrees as part of the teams, a result that did not differ between public and private facilities. The presence of healthcare professionals in these departments is strategic because they have the skills to understand the demands and needs of healthcare professionals and patients, assisting in the development and implementation of ICT in the sector. The literature shows that the presence of professionals with health informatics degrees can make teams more productive, increasing skills and clearly defining the expectations for everyone's roles. Because it is an interprofessional and multiprofessional area, knowledge of health processes and flows helps to streamline projects and contributes to greater assertiveness (Holden, Binkheder, Patel, & Viernes, 2017).

Regarding technical support in IT areas, 21% of Brazilian healthcare facilities had in-house teams to perform this service, while 39% had service providers hired by the facilities. Chart 3 highlights the differences in technical support between public and private health systems and types of facilities. In 65% of public facilities, the service was performed by providers hired by health departments, a percentage that remained stable compared to the previous year. In 2019, this service was performed by providers hired by the facilities in 69% of private facilities, compared to 78% in 2018. There was also a five-percentage point increase compared to the previous year in the number of private facilities in which support was carried out by in-house teams. Considering types of facilities, it is noteworthy that 67% of inpatient facilities with more than 50 beds had in-house teams to perform IT technical support.

CHART 3

HEALTHCARE FACILITIES BY MAIN PERSON RESPONSIBLE FOR COMPUTER TECHNICAL SUPPORT (2019)

Total number of healthcare facilities that used the Internet in the last 12 months (%)



Regarding information security and privacy, the postponement of the enactment of the Brazilian General Data Protection Law (LGPD) due to the COVID-19 pandemic ended up extending the deadline by which the health sector, as well as all other

sectors that collect and/or store personal information, has to adapt to the guidelines established by the new law.⁴

In accordance with laws that are in force in other countries, the LGPD aims to ensure the right to privacy and the protection of personal data. Considering this, adjustments are necessary in all institutions that deal with personal data, especially in the health sector, in both the area of clinical research and in the use of Artificial Intelligence and Big Data. In addition, data stored in patients' electronic health records are characterized as sensitive and can be used in a discriminatory manner, and therefore require special protection (Guanaes, 2018; Spagnoli & Soares, 2019; Sarlet & Molinaro, 2019; Pinheiro, 2018; Siqueira & Hoch, 2019). Among the various requirements of the law are the adoption of information security measures that guarantee the protection of personal data against unauthorized access and accidental or illegal situations, as well as the creation of best governance practices that establish procedures, security standards, educational actions, and risk mitigation in the treatment of such data.

The ICT in Health 2019 survey reveals challenges faced by some healthcare facilities in complying with this law, both in relation to the standardization and regulation of patient information security policies and in relation to the security tools adopted. Considering the LGPD⁵ recommendation of creating best practice and governance rules, including information security standards and regulations, the survey data indicated a gap in the adoption of specific standards to treat and access patient data among the healthcare facilities. In 2019, about a third (31%) of healthcare facilities had information security policies. In relation to 2018, there was an increase in this proportion among facilities located in the Southeast (from 22% to 43%) and in non-capital municipalities (from 18% in 2018 to 27% in 2019). In the remaining facilities, this proportion remained stable. In addition, a larger proportion of inpatient facilities with more than 50 beds (56%), private facilities (44%), and those that provide diagnosis and therapy services (37%) were in line with the law's recommendation of having explicit information security policies. Among public facilities, only 16% had such policies.

On analyzing the information security tools used by healthcare facilities, there was a positive variation in the percentage of facilities that used biometric-protected access to electronic systems – from 8% in 2018 to 16% in 2019 – and a decrease in the availability of digital certificates – 35% in 2019 against 45% in 2018. Considering types of facilities, inpatient facilities with more than 50 beds and those that provide diagnosis and therapy services showed the best results in the adoption of information security tools, including the most sophisticated data protection tools such as cryptography, digital certificates and electronic signatures (Chart 4).

Starting in 2019, in addition to the data protection tools already investigated in previous editions of the survey, two others were added: data loss protection/prevention (DLP) and two-factor authentication. In total, 22% of health facilities used

⁴ Provisional Measure No. 959, of April 29, 2020, which postponed the enactment of the Brazilian General Data Protection Law (LGPD). See more information on the proceedings on National Congress' website. Retrieved on August 15, 2020, from <https://www.congressonacional.leg.br/materias/medidas-provisorias/-/mpv/141753>

⁵ Article 50 of the Brazilian General Data Protection Law (LGPD).


DLP, with the highest percentage observed in diagnosis and therapy services (29%) and in inpatient facilities with more than 50 beds (23%). This tool was also present in 29% of private facilities and 14% of public facilities. DLP is used to monitor events that can result in data loss, diagnosing and correcting system vulnerabilities. It acts preventively so that no sensitive data is improperly accessed and shared, whether by people who work in the facility or by external data theft threats.

Two-factor authentication was present in only 7% of facilities. This tool provides more security in accessing electronic systems by requiring authentication in two steps. There are different types of systems, but in general, they request a password and a second authentication factor, which can be a confirmation via code obtained from an application or SMS. This feature makes unauthorized access to electronic systems of health facilities harder to accomplish.

CHART 4

HEALTHCARE FACILITIES BY TYPE OF INFORMATION SECURITY TOOL USED (2019)

Total number of healthcare facilities that used the Internet in the last 12 months (%)



The perceptions of system security and privacy were considerably inferior among managers of public facilities. For 45%, the electronic systems available were secure and guaranteed the confidentiality and privacy of information, a percentage much lower than that found among managers of private facilities (82%). When considering

types of facilities, the managers of diagnosis and therapy services (82%) and inpatient facilities with more than 50 beds (68%) agreed the most with this statement. In inpatient facilities with up to 50 beds (48%) and outpatient facilities (61%), managers had a more critical assessment.

Electronic health records and information exchange

Electronic health records are tools that enable institutions to monitor and access patient data in a timely and standardized way. Electronic records allow for the integration of patient care among team members of specific facilities (horizontal integration) and among healthcare providers at different levels of care – primary, secondary, and tertiary (vertical integration). At the same time, the more complex the electronic system present in the facility, the better its ability to reduce fragmentation in care provision, favoring quality and efficiency, as well as reducing gaps in care (Janett & Yeracaris, 2020). In the context of pandemics, patient records become more important in terms of public health (Stoeger & Schmidhuber, 2020) and data about diagnoses and prescribed medications can be used to identify people in COVID-19 risk groups, for example.

Greater availability of patient data in electronic format is highly important for decision-making and continuity of care in the public and private sectors, especially with the exchange of information between them⁶. In the context of the COVID-19 pandemic, the Ministry of Health is monitoring the development of the National Health Data Network (RNDS), a platform that allows electronic health record systems to connect and exchange information about patients' health. The platform has been used in the strategy to combat and control the pandemic in the country, since all public and private laboratories must notify the Ministry of Health of the results of COVID-19 tests within 24 hours through the RNDS.⁷

Data from the ICT in Health 2019 survey indicated an expansion in the adoption of electronic systems in health facilities. In 2019, 82% had electronic systems to record patient information, a proportion that was 73% in 2018. An estimated 18,000 facilities still did not have electronic systems.

While nine out of ten private facilities (88%) had electronic systems to record information about their patients, this proportion was 74% among those in the public sphere. This means that this resource was not available to about 12,000 public healthcare facilities in 2019 (Chart 5). In regional terms, those located in the South (90%) and Southeast (83%) regions showed higher levels of adoption of these systems when compared to those in the Center-West (78%), Northeast (77%) and North (74%).

⁶ Argument presented by Jackson Barros, director of Datasus, during an online presentation at the webinar "COVID-19: the importance of using data in health decision-making," organized by the National Association of Private Hospitals (Anahp) in June 2020. Retrieved on August 15, 2020, from <https://www.anahp.com.br/noticias/noticias-anahp/especialistas-discutem-a-importancia-do-uso-de-dados-na-saude-brasileira-em-tempos-de-pandemia/>

⁷ More information available on the Ministry of Health's webpages. Retrieved on August 15, 2020, from <https://rnnds.saude.gov.br/> and from <https://saudedigital.saude.gov.br/material-de-apoio/>


The presence of electronic systems was also uneven among facilities located in non-capital cities (79%) compared to those in capital cities (92%).

Regarding types of facilities, inpatient facilities with more than 50 beds and diagnosis and therapy services presented a greater proportion of electronic systems to record patient information (91% in both cases), while inpatient facilities with up to 50 beds had the lowest proportion (67%).

CHART 5

HEALTHCARE FACILITIES BY AVAILABILITY OF AN ELECTRONIC SYSTEM TO RECORD PATIENT INFORMATION (2019)

Total number of healthcare facilities that used the Internet in the last 12 months (%)



The increased presence of electronic systems for recording patient information is reflected in how this information is stored physically or digitally. In relation to 2018, there was a reduction in the proportion of facilities that stored health records only on paper, from 27% to 18%. At the same time, the proportion of those that kept information records partly on paper and partly in electronic format grew from 54% to 64%. The percentage of facilities that stored the information only in electronic format did not change compared to the previous survey (18%).

The reduction of those who kept patient records only on paper occurred mainly among public facilities (from 38% in 2018 to 28% in 2019), in outpatient facilities (from

30% to 19%), and in those located in non-capital municipalities (from 32% to 20%). Within the scope of federal management, this topic is part of the Digital Health Strategy for Brazil, an initiative of the Ministry of Health that aims to strengthen the healthcare network by computerizing health management and care, with a focus on primary care, providing for actions such as the definition and implementation of e-Health systems and services integrated with the SUS (Ministry of Health [MS], 2017).

Despite these advances, the process of computerizing patient data in the public sector is still suboptimal. When compared to private facilities, the proportion of public facilities that stored this information only on paper was almost threefold – 28% against 9% among private facilities. In 2019, about a quarter (23%) of private facilities kept patient information only in electronic format, in comparison with only 12% of public facilities.

Furthermore, an upward trend was observed in the availability of information in electronic health records. The most significant increases were observed in patient demographics (89% in 2019, 10 percentage points greater than 2018); the main reasons that led the patient to the medical service or appointment (64% in 2019 against 50% in the previous edition); and patient admission, transfer and discharge (56% in 2019 against one-third of facilities in 2018). This trend of computerizing the collection and use of patient information occurred among public institutions, outpatient facilities, and those in non-capital municipalities, the same strata that had considerable increases in the adoption of electronic systems.

Inpatient facilities with more than 50 beds had the greatest availability of patient data in electronic format, since the various types were available in more than half, especially patient demographics, patient admission, transfer and discharge, and the main reasons that led the patient to the medical service or appointment. Outpatient facilities presented higher availability of this data in relation to the previous year.

TABLE 2

HEALTHCARE FACILITIES BY TYPE OF PATIENT DATA ELECTRONICALLY AVAILABLE (2019)*Total number of healthcare facilities that used the Internet in the last 12 months (%)*

Types of data	Total	Outpatient	Inpatient (up to 50 beds)	Inpatient (more than 50 beds)	Diagnosis and therapy services
Patient demographics	89	89	72	90	90
Detailed clinical notes from encounter with clinician or medical history	65	67	49	75	58
Main reasons that brought patients in for medical services or appointment	64	67	61	82	48
Patient's diagnosis, health problems or conditions	64	66	50	77	53
Lab test results	61	59	53	75	74
Patient admission, transfer and discharge	56	58	65	90	34
Allergies	54	56	44	71	41
Prescribed medication list	53	57	45	73	29
Nursing notes	51	56	42	70	25
Immunization	46	52	32	51	16
Patient's vital signs	45	47	47	70	24
Radiology test results (reports)	38	38	38	68	31
Radiology test results (images)	24	22	34	65	27


Regarding the functionalities of the electronic systems, Chart 6 shows those available in the greatest number of facilities by type. In general, the most available were administrative functionalities, such as booking appointments and requesting lab tests. However, even within this group, more complex functionalities, such as listing information about a specific patient or listing information about tests and medications of all patients, were present only in one-quarter of healthcare facilities.

Decision support functionalities – important for professionals to receive information about the procedures recommended in the services they perform, assisting in decisions about diagnoses and treatments – were available in a smaller number of facilities. Within this group, the most present were clinical guidelines, best practices, or protocols (27%), and drug allergy alerts and reminders (24%). All other functionalities investigated by the survey were present in approximately one-fifth of Brazilian healthcare facilities. It is worth noting that decision support systems require patient registration. Therefore, they require background information about patients so that functionalities such as alerts, reminders, and guidelines can be recommended to improve care outcomes. Such systems must be integrated into records or charts for professionals to adhere to and use them (Sutton et al., 2020).

Information exchange functionalities between electronic systems among different facilities was also less frequently available. The viability of this exchange is important to consult, modify or guarantee the treatment provided when patients need to be transferred from one institution to another, especially between the different levels of health care, according to the degree of severity of the patients' conditions. The most commonly available information exchange functionalities were sending or receiving electronic referrals (38%) and reports on the care provided to patients at the time of discharge or referral to other facilities (34%).

Among public facilities, growth was observed in functionalities such as listing lab test results for a specific patient (from 17% in 2016 to 41% in 2019), listing patients on a specific medication (from 18% in 2016 to 40% in 2019) and writing medical prescriptions (from 29% to 51% in the same period). In relation to private facilities, the functionalities with the greatest growth between 2016 and 2019 were: requesting imaging tests (from 33% to 51%); requesting lab tests (from 36% to 51%); and booking appointments and tests (from 53% to 67%).

CHART 6

HEALTHCARE FACILITIES BY AVAILABLE ELECTRONIC SYSTEM FUNCTIONALITIES (2019)*Total number of healthcare facilities that used the Internet in the last 12 months (%)*

Considering the need to exchange information about patients, especially in the public health system, since 2018 the ICT in Health survey has investigated whether electronic systems available in the facilities receive or send information directly to other electronic systems in the primary, specialized, or hospital healthcare network. The purpose of this indicator is to map the presence of minimum interoperability standards⁸. In 2019, 19% of Brazilian healthcare facilities sent or received clinical information to/from their electronic systems to/from other systems in the healthcare network, a proportion that remained stable compared to 2018. This type of information exchange among systems was more common among public facilities (25%) and inpatient facilities with more than 50 beds (31%).

Online services provided to patients and telehealth

In Brazil, the number of Internet users has increased in recent years across all social classes. In 2019, 74% of the Brazilian population 10 years old or older accessed the Internet, with greater demand for information on websites and social networks (CGI.br, 2020c). The COVID-19 pandemic has intensified the search for health information. According to data from the Panel ICT COVID-19, conducted in July 2020, 72% of Internet users 16 years or older searched for health-related information, a considerable increase

⁸ A general analysis conducted by the Digital Health Strategy indicates that there are important projects and initiatives in the public and private sectors, but that there is poor alignment between these initiatives. Additionally, it presents a detailed analysis of electronic health records (EHRs), telehealth, mobility support, patient flow management, health unit management and operation, and integrated management of SUS (MS, 2017, p. 51).

compared to the same reference population in 2019, when 55% searched for this type of information (CGI.br, 2020d).

During health emergencies, as in cases of outbreaks, epidemics, and pandemics, communication is essential and access to safe and accurate information helps both responsible bodies and populations cope with crises (MS, 2020b). The Internet is also an increasingly important communication channel between healthcare facilities and users, especially in the dissemination of information about prevention and health care. Schedules for when medical specialties provide care, distribution of medications, information about booking appointments, and issues related to pharmacies and labs can be found on the Internet. Making this information available online allows users to avoid needless commutes. The greater presence of healthcare facilities on the Internet also makes it possible to expand the provision of more precise, secure and reliable information to citizens and help combat misinformation in the context of the pandemic (Sousa, Raasch, Soares, & Ribeiro, 2020).


Although the online presence of healthcare facilities is still low, it has grown in recent years: from 2015 to 2019, the proportion of facilities that had websites increased from 39% to 45%, as did the proportion of those who had profiles or accounts on online social networks, from 33% to 46%. In the same period, the proportion of facilities that were not present on any of these online platforms decreased from 48% to 36%.

Internet presence varied greatly according to the different profiles of healthcare facilities. Private facilities (50%), inpatient facilities with more than 50 beds (51%), and those that provided diagnosis and therapy services (48%) had the greatest online presence, on both websites and social networks (Chart 7). At the same time, more than half of public facilities (57%), approximately one out of ten outpatient facilities (39%), and inpatient facilities with up to 50 beds (44%) were not present on any of these platforms.

CHART 7

HEALTHCARE FACILITIES PRESENT ON THE INTERNET THROUGH WEBSITES AND/OR SOCIAL NETWORKS (2019)

Total number of healthcare facilities that used the Internet in the last 12 months (%)




Social isolation measures to prevent COVID-19 have resulted in the need to expand the provision of services via the Internet in various areas, such as commerce, education, banking, government, and health. If health services such as booking appointments and tests were available on the Internet, especially in the public system – in which a majority of users still need to go to PHUs in person – then this population would not need to leave their homes to carry out this step of the process. Furthermore, automation would also increase the efficiency of the service both for facilities and patients.

Despite the relevance of the provision of services online and the central role of the Internet in people's daily lives, the ICT in Health 2019 survey indicated that, immediately before the pandemic, the availability of these services – such as booking appointments and tests, and viewing test results, among others – was still very low in the country. The offer of these services still differs between types of facilities and administrative jurisdictions. Online booking of services was offered by about a quarter of healthcare facilities in 2019, a proportion that has remained stable throughout the historical series of the survey. Booking tests (39%) and viewing lab tests results (60%) on the Internet was most commonly present in facilities that provided diagnosis and therapy services, due to the nature of their operations. The services less available online to patients from all types of healthcare facilities were the possibility of patients viewing their electronic health records and interacting with medical teams.

CHART 8

HEALTHCARE FACILITIES BY SERVICES OFFERED TO PATIENTS THROUGH THE INTERNET (2019)

Total number of healthcare facilities that used the Internet in the last 12 months (%)



Public and private facilities presented stable proportions of online services, and in public facilities, there was a lower frequency of those that offered all the types of services analyzed by the survey: booking appointments (21% in public and 27% in private facilities), booking tests (17%, compared to 28% in private facilities) and viewing tests results (20% vs. 33% in public and private facilities, respectively).

Some initiatives have been developed to expand the provision of these services through the Internet, especially at the municipal level. One example is the app Agenda Fácil (“Easy Scheduling”), developed by the city of São Paulo, which allows users to schedule, confirm and cancel appointments and tests at the municipality’s PHUs. According to data from the ICT Electronic Government 2019 survey (CGL.br, 2020e), 25% of local governments offered online services for scheduling appointments, assistance, and services on their websites in 2019. Another initiative is the Conecte SUS app (“Connect SUS”), created by the Ministry of Health to enable interaction with citizens (Ordinance No. 1434/2020). This initiative is part of the Digital Health Strategy and provides access to appointments, tests, prescribed medications, data and orientation about blood donation, as well as vaccination cards to help control information about doses, batches and validity.

TELEHEALTH SERVICES

Telemedicine is an effective tool to promote necessary social distancing in clinical settings during the pandemic. Healthcare systems around the world have faced the dilemma of maintaining their capacity to provide services to COVID-19 patients and those with other acute or chronic diseases while also protecting the health of their professionals (Bashshur, Doarn, Frenk, Kvedar, & Woolliscroft, 2020).

Several studies have described experiences of implementing telemedicine in other countries. Among them, special mention goes to a study developed by Ohannessian, Duong and Odone (2020). They reported how telemedicine, especially video conferencing, has been adopted to reduce the risk of transmission in the United States and the United Kingdom. The study also showed that most countries face challenges to implementing a regulatory framework for telemedicine that authorizes, integrates, and reimburses these services. Italy, for example, has not included telemedicine in the essential levels of patient care of its National Health Service, while France already has an advanced structure that promotes the use of telemedicine.


Additionally, Mann, Chen, Chunara, Testa and Nov (2020) presented a case study on the use of telemedicine at NYU Langone Health, at the epicenter of the COVID-19 outbreak in the United States. The authors pointed out that, after the expansion of the virtual team, emergency and non-emergency care via telemedicine increased by more than 600% between March and May 2020, and 56% of emergency care was related to COVID-19. The study concluded that the rapid expansion of and adaptation to telemedicine resulted in greater efficiency of care and prevention of disease dissemination, as well as recommending that other health systems anticipate and regulate telemedicine.

Bashshur et al. (2020) highlighted that the rapid advance of telemedicine in this period contrasts with its slow adoption by countries, despite the existence of several studies pointing to its relevance and numerous positive experiences with its implementation. In Brazil, the regulation of telehealth has been widely discussed in recent years because of its possible impacts on access to health care by the population, especially for those who reside far from urban centers. Its use can bring several benefits, such as reducing time of care, wait times for appointments, and travel costs for patients and professionals, and improving quality of care (Caetano et al., 2020; Caffery, Farjian, & Smith, 2016).

In the context of the COVID-19 pandemic, telehealth also enables pre-consultation for screening, less complex treatment of other types of diseases, and decreased circulation of people in healthcare facilities and contaminated environments. These actions contribute to reducing the risk of contamination and dissemination of the disease, as well as freeing up hospital beds and vacancies for infected patients (Caetano et al., 2020). Encouraging the development of telehealth can be important to ensure the ongoing training of healthcare professionals, especially those who do not have access to the main Brazilian teaching centers. Programs in this area include the Brazil Telehealth Network Program, which provides ongoing education to healthcare professionals, as well as teleconsultation, telediagnosis, and formative second opinions. The goal is to provide training based on the challenges related to work in the area, improving the quality of care provided (Silva, 2017).

Within the limits of Ordinance No. 2546, of October 27, 2011, which was in force at the time of data collection, the survey investigated the adoption and availability of telehealth services by Brazilian healthcare facilities. The results showed that public facilities had greater availability of telehealth services than private facilities. The main service offered was distance learning in health care, present in 33% of public facilities against 8% of private facilities, followed by teleconsulting services (28% vs. 3%) and distance research activities (25% vs. 5%). It is also worth noting that facilities located in the North and Northeast regions provided more resources for distance research activities (20% in both) than that observed in the Southeast (10%), South (14%) and Center-West (13%). The other investigated items were most present in the Northeast and Center-West regions, as shown in Chart 9.

CHART 9

HEALTHCARE FACILITIES BY TELEHEALTH SERVICES AVAILABLE (2019)*Total number of healthcare facilities that used the Internet in the last 12 months (%)*

Participation in telehealth networks was also higher among public facilities, while in private facilities, it was practically nil. Among public facilities, 32% of managers stated that the facilities participated in state telehealth networks, 19% mentioned they were part of the Brazil Telehealth Network Program, and 11%, the Telemedicine University Network (Rute). However, 47% of public facilities were not connected to any telehealth network. Considering geographic regions, it is worth noting that about one-fifth (19%) of healthcare facilities in the South and Center-West participated in state networks, and that 13% of the those in the North and 15% of those in the Northeast participated in the Brazil Telehealth Network Program.

ICT adoption in primary healthcare units

Primary healthcare units (PHUs) play an essential role in local population health surveillance through prevention and disease notification. According to the Ministry of Health⁹, primary care is where patients can receive closer follow-up care by healthcare teams and where most of the population's health problems can be resolved.

In the face of epidemiological outbreaks and pandemics, primary health care takes on a leading role due to the nature of its main functions, namely: having knowledge of catchment areas; establishing links between patients and health teams; monitoring

⁹ More information on the Ministry of Health's website. Retrieved on August 15, 2020, from <https://www.saude.gov.br/noticias/agencia-saude/46492-mais-de-3-mil-municipios-fazem-parte-do-programa-de-informatizacao-do-sus>

families in vulnerable situations; and following-up on suspected or mild cases. Furthermore, studies have shown that, in several countries, about 80% of patients with mild cases and most of those with moderate cases of COVID-19 seek out primary care facilities for initial assistance and to receive care (Sarti, Lazarini, Fontenelle, & Almeida, 2020; Dunlop, Howe, Li, & Allen, 2020).

The information system of PHUs, through teleservices, can provide more efficiency and agility in monitoring patients who are in risk groups or who present mild symptoms and should remain in social isolation. Teleservices also make it easier to refer more severe cases to specialized care and reference units (MS, 2020b). It is increasingly evident how important it is that PHUs throughout the country be connected and computerized.


Given the relevance of computerization of PHUs in order to improve the functioning and organization of the entire healthcare system, the results of the ICT in Health 2019 survey pointed to one of the main challenges for public managers, because PHUs were the facilities with the lowest availability of computers and Internet access. In 2019, 91% had computers and 82% had Internet access, results that remained stable compared to 2018 (90% had computers and 80% had internet access). In the universe of 40,880 PHUs considered in the survey, an estimated 3,600 did not yet have computers and about 7,200 were not connected to the Internet.

Among PHUs with computers, the percentage of those with tablets has increased in recent years. In 2019, 26% had tablets, while in 2018 and 2017 this percentage was 18% and 9%, respectively. Other types of devices, such as desktop computers (98%) and laptops (29%), showed no significant changes in the period.

Regarding types of connections used, 96% of PHUs had access to fixed broadband¹⁰, and most (79%) were connected via cable or optical fiber, a proportion that has grown in comparison with previous years (Chart 10). There was a small reduction in the number of PHUs with radio and satellite connections. The percentage of PHUs with mobile connections remained stable.

¹⁰ The concept of fixed broadband corresponds to connection via cable or optical fiber, telephone line (DSL), radio, and satellite.

CHART 10

PRIMARY HEALTHCARE UNITS BY TYPE OF CONNECTION (2017 - 2019)*Total number of healthcare facilities that used the Internet in the last 12 months (%)*

New policies aimed at increasing the connectivity of PHUs are being implemented, such as the Conecte SUS program, which launched a pilot project to computerize PHUs and provide training courses in ICT and data analysis to public employees who work at municipal health departments. Moreover, the Ministry of Science, Technology and Innovation (MCTI), in partnership with the Ministry of Health, is working to expand the connection of PHUs with family health strategy (FHS) teams. Within this program, the National Education and Research Network (RNP) is responsible for managing public bids and contracting local providers to connect approximately 16,000 PHUs. Priority is being given to the contracting of optical fiber connections, and, when unavailable, radio and satellite connections are considered as alternatives (National Education and Research Network [RNP], 2020).

In addition to types of connections, another important piece of data for mapping the ICT infrastructure of PHUs is the range of the download speeds of the main Internet connections. In 2019, there was an increase in the number of facilities that hired higher ranges of download speeds of the main Internet connections and a reduction in slower ranges. PHUs with connections up to 1 Mbps went from 11% in 2018 to 8% in 2019. Connections over 10 Mbps were present in 17% of PHUs, an increase of five percentage points compared with 2018. It is important to highlight the tendency toward an increase in the percentage of managers who did not know the hired connection speed for the facility. This result can be explained by the fact that, in general, ICT infrastructure services in the PHUs are contracted by health departments, and therefore, local management is not involved in this decision.

Health departments also play an important role in ICT management and governance in PHUs. In 2019, only 10% of PHUs had IT or informatics areas, departments or


sectors. In the others, most of the technical support was carried out by providers hired by health departments (71% of PHUs). In 10% of PHUs, this service was performed by in-house teams, in 6% by providers hired by other institutions, and in 1% by providers hired by the PHUs.

Considering recent discussions on information security, the results of the survey showed that the presence of security tools in PHUs was still very low, as shown in Chart 11. Among the items investigated, the most used tools were still antivirus software (81%) and password-protected access to electronic systems (72%). Tools such as cryptography of files and e-mails, database cryptography, electronic signatures and biometrics-protected access to electronic systems showed a positive variation compared to 2018.

CHART 11

PRIMARY HEALTHCARE UNITS BY TYPE OF INFORMATION SECURITY TOOL USED (2017 - 2019)

Total number of healthcare facilities that used the Internet in the last 12 months (%)



Still regarding data protection, 15% of PHU managers said that the facilities had information security policies, a proportion that has remained stable throughout the survey's historical series.

When asked about their assessment of IT infrastructure and IT management and governance, 40% of PHU managers agreed that IT devices were new and up-to-date,


32% said that Internet connections fit facility needs, and 36%, that PHUs had appropriate IT technical support. This data points to limited ICT infrastructure and management in PHUs, which is essential for integration of the healthcare system. These facilities are the foundation for the success of computer system strategies in the field of public health, such as e-SUS PHC¹¹ and other similar initiatives, offering citizens more access and better services.

In 2019, the situation of PHUs in relation to keeping electronic records of patient information improved: 78% had electronic systems for this purpose, an increase of nine percentage points compared to 2018. This positive variation in the adoption of electronic health records (EHRs) has impacted how clinical and demographic information is stored in patients' medical records. There was a decrease in the percentage of PHUs that recorded patient information only on paper-based format. As pointed out in Chart 12, in 2018, this group represented more than one-third of PHUs (35%) and, in 2019, this proportion decreased to one-quarter. Additionally, the percentage of PHUs that kept this information partly on paper and partly in electronic format increased from 53% in 2018 to 59% in 2019.

CHART 12

PRIMARY HEALTHCARE UNITS BY TYPE OF METHOD USED TO KEEP PATIENT MEDICAL RECORDS (2017 - 2019)

Total number of healthcare facilities that used the Internet in the last 12 months (%)



These results point to a moment of transition in the process of digitalization. However, despite the downward trend in the number of PHUs that used only paper to keep records, there was no significant growth in the number of facilities that only kept electronic records of patients' clinical and demographic information. Among the PHUs that kept this information in electronic format, 39% also printed it, a proportion that remained practically stable compared to 2018 (35%). The need to print patient charts can be justified by occasional internal control procedures of care provided in the facility.

¹¹ The e-SUS Primary Healthcare Strategy (e-SUS PHC) is a strategy of the Family Health Department that aims to restructure primary health care (PHC) information at the national level. This program is part of the proposal for restructuring the Health Information Systems developed by the Ministry of Health. More information available at the Ministry of Health's website. Retrieved on August 15, 2020, from <https://aps.saude.gov.br/ape/esus>

These results may also point to difficulties in accessing electronic information in consultation rooms that do not have computers or in facilities where the demand is higher than the availability of devices. In 55% of PHUs, professionals were able to access patient information from any location in the facilities on an internal network, via laptops, tablets or mobile phones, while in only 34% could this data be accessed from outside the facilities, via the Internet.

The availability of different types of patient information in electronic format for consultation has been growing in recent years. Since 2017, all the information investigated by the survey has shown a positive variation. Chart 13 shows that, in 2019, the information most available in electronic format was patient demographics (87%) and patient immunizations (80%).

The information that most increased in relation to 2018 was: the main reasons that led the patient to the medical service or appointment (before they could be viewed electronically in 60% of facilities, and in 2019, they were available in 78%); patients' diagnoses, health problems and conditions (from 61% to 76%); allergies (54% to 69%); and admission, transfer and discharge (45% to 59%).

CHART 13

PRIMARY HEALTHCARE UNITS BY TYPE OF PATIENT DATA AVAILABLE ELECTRONICALLY (2017 - 2019)

Total number of healthcare facilities that used the Internet in the last 12 months (%)





Chart 14 shows the functionalities that were most available in PHUs, by classification. Those related to administrative activities were present in more facilities and have presented an upward trend in recent years. Decision-support functionalities were less present in PHUs: approximately one out of four. Those that provided information exchange with other facilities were also present in a low number of PHUs and have not shown a significant increase in recent years.

CHART 14

PRIMARY HEALTHCARE UNITS BY AVAILABLE ELECTRONIC SYSTEM FUNCTIONALITY (2017 - 2019)

Total number of healthcare facilities that used the Internet in the last 12 months (%)



The online presence of PHUs can contribute to the dissemination of immunization campaigns and disease prevention, as well as facilitate access to information on service schedules – an essential aspect for immunization strategies related to COVID-19. However, only 21% had websites and 20% had profiles or accounts on social networks. Regarding the provision of online services to patients, there were no significant changes since the previous edition. In 2019, 23% of PHUs offered patients the possibility of booking appointments, 22% allowed viewing lab results, and 20% offered booking lab tests online. The possibility of viewing patient charts (12%) and interacting with medical teams (7%) through the Internet was even less frequent.

Telehealth services were more present in PHUs. In 2019, 39% offered distance learning in health care. Approximately one-third provided teleconsulting services (35%) and distance research activities (30%). Telediagnosis services were provided by 25% of PHUs, formative second opinions by 20%, and remote patient monitoring by 8%.

Regarding participation of PHUs in telehealth networks, in 2019, 57% of managers said that the units participated in networks, which represented a positive variation in relation to that observed in 2018 (48%). Among the networks investigated, 40% of the PHUs participated in state telehealth networks, 23% were part of the Brazil Telehealth Network Program, 14% were in the Rute Network of the RNP, and 11% participated in other telehealth networks.

ICT access and use by healthcare professionals

The use and appropriation of ICT by healthcare facilities is an essential factor for the success of digitalization of healthcare facilities. The proper training of these professionals is an important factor for the advancement of digital health, as well as their engagement in the adoption of new devices and systems in patient care routines.

The availability of computers for use by physicians and nurses has remained relatively stable in recent years. In 2019, 88% of physicians had computer access at health facilities and 94% had Internet access. In addition, among physicians who worked in public facilities, 23% said they did not have computers available, a high percentage compared to those who worked in private facilities (3%). Among nurses, 90% had computers and 92% had Internet access. The difference in computer availability between nurses from private and public institutions was slightly lower compared to that between physicians, considering that 86% of nurses in public facilities and 98% of those in private facilities reported having computers available.

The use of computers in patient care influences how medical prescriptions are written. Most physicians who had access to computers wrote medical prescriptions electronically (54%), and 31% wrote them both by hand and electronically, proportions that remained stable compared to previous years. In 2019, 14% of doctors said they wrote their prescriptions only by hand, a proportion that remained the same in relation to 2018. It is worth highlighting that, in inpatient facilities with more than 50 beds, 75% of physicians wrote prescriptions in electronic format.

Despite the use of computers when writing prescriptions, most physicians continued to sign them by hand (71%), which points to much room to expand the use of digital certificates, adopted by only 12% of physicians. Even in inpatient facilities with more than 50 beds, most (74%) signed their prescriptions by hand. With the new teleconsultation regulations due to the COVID-19 pandemic and the need for social distancing, there has been progress in the regulation and use of electronic prescriptions in the country.¹²

Regarding the professionals' perception of ICT infrastructure and management in

¹² More information available in Ordinance No. 467/2020.

the facilities where they work, about half of the physicians and nurses agreed that the Internet connection fit their needs (53% for both) and that the facility had appropriate IT technical support (52% for both). As for the IT devices available in the facility where they worked, 45% of physicians and 46% of nurses agreed that they were new and up-to-date. In general, ICT infrastructure was better assessed by professionals who worked in private facilities.

ELECTRONIC SYSTEMS AND THE USE OF FUNCTIONALITIES BY HEALTHCARE PROFESSIONALS

The availability of electronic records of patient health information is essential to ensure better care and diagnosis, as well as to optimize the decision-making of healthcare professionals, because it allows for systematic and quicker access to and monitoring of greater volumes of data.

Among the data kept in electronic records constantly accessed by both physicians and nurses were: the main reasons that led patients to the medical service or appointment; patients' diagnoses, health problems or conditions; and detailed clinical notes from encounters with clinicians or medical history, as shown in Charts 15 and 16. The frequency of data consultation remained stable in relation to 2018, with the exception of patient demographics, which increased considerably among both physicians (from 33% in 2018 to 63% in 2019) and nurses (from 41% in 2018 to 59% in 2019).

CHART 15

PHYSICIANS BY HOW OFTEN THEY REFER TO PATIENT DATA ELECTRONICALLY AVAILABLE (2019)

Total number of physicians with computer access in the healthcare facility (%)





CHART 16

NURSES BY HOW OFTEN THEY REFER TO PATIENT DATA ELECTRONICALLY AVAILABLE (2019)*Total number of nurses with computer access in the healthcare facility (%)*

The presence of security features for accessing patients' clinical and demographic information is paramount to ensure the protection of the stored information. In this regard, password-protected access to electronic systems was still the tool most used by both physicians (94%) and nurses (91%). One-quarter of physicians (26%) and nurses (25%) said they had used digital certificates, while less than one-tenth of physicians (8%) and nurses (5%) had used biometrics-protected access to electronic systems.

The differences in the nature of the activities and roles of physicians and nurses were more highlighted in the types of electronic system functionalities they used most frequently. As seen in Charts 17 and 18, approximately half of the physicians always used the functionality of requesting lab tests, and four out of ten always used functionalities relative to requesting image tests and listing medications being taken by a specific patient. Nurses resorted more to the following functionalities: listing medications being taken by a specific patient; generating requests for materials and supplies; and listing lab test results for a specific patient.

CHART 17

PHYSICIANS BY HOW OFTEN THEY USE THE AVAILABLE ELECTRONIC SYSTEM FUNCTIONALITIES (2019)

Total number of physicians with computer access in the healthcare facility (%)





CHART 18

NURSES BY HOW OFTEN THEY USE THE AVAILABLE ELECTRONIC SYSTEM FUNCTIONALITIES (2019)

Total number of nurses with computer access in the healthcare facility (%)



ADOPTION OF TELEHEALTH STRATEGIES BY PROFESSIONALS

Telehealth can overcome geographic barriers and facilitate allocation of healthcare professionals; therefore, its implementation can significantly expand access by citizens to higher quality, more equitable, and more efficient care. The ICT in Health 2019 survey indicated that the main telehealth service available in

facilities was distance learning, an important result in terms of ongoing education of professionals in the sector.

Other resources remained little available in healthcare facilities. Distance research activities, teleconsulting, formative second opinions and teleradiology were used by approximately one-quarter of healthcare professionals. Remote patient monitoring was used by only 9% of physicians and 16% of nurses.

In relation to 2018, the availability of distance learning in health care, in the case of physicians, increased in the Southeast (20% to 52%) and in facilities in non-capital cities (21% to 43%). Distance research activities decreased in the same period among nurses (from 43% to 28%). Throughout the survey's entire historical series, distance learning in health care has been the most available telehealth resource for nurses in the facilities in which they worked. In 2019, this resource was available to 44% of nurses, reaching 61% of those who worked in PHUs.

ICT APPROPRIATION BY PHYSICIANS AND NURSES

For the development and adoption of new technologies in the health area to be efficient – not only in the management of information and healthcare facilities, but also in patient care and access to the health system – it is important that professionals receive adequate training in ICT.

However, a small proportion of healthcare professionals has carried out capacity-building courses in the health informatics area. In 2019, the training or capacity-building course with the most adherence among nurses (36%) and physicians (30%) was health informatics, especially among physicians who worked in private facilities (40%). Participation in specialization courses (6% of physicians and 8% of nurses), master's programs (1% of physicians and 1% of nurses), and PhD programs (1% of physicians) in health informatics was less frequent.

The appropriation of ICT in the work of physicians and nurses can also be observed in how they perceive the impact of these technologies on their activities. In 2019, most nurses (60%) perceived neither an increase nor a decrease in the workload with the use of computers and the Internet. Those who perceived an impact were divided equally among those who believed the workload had increased (22%) and those who said it had decreased (17%). However, it is important to emphasize that the perception that computer use increased workloads was more common among nurses who worked in public facilities (25%) and in PHUs (37%) when compared to those in private facilities (16%).

Even though most physicians did not perceive any difference in their workloads (43%), the percentage of those who reported reduced workloads due to computer and Internet use (33% in 2019) was higher than that of nurses. This perception of physicians about computer and Internet use decreasing workloads may be a consequence of the higher frequency with which these professionals use computers in patient care.

In general, the assessment of the impacts of the use of electronic systems by healthcare professionals was positive, as illustrated in Charts 19 and 20. The main

benefits of ICT mentioned by physicians were improvement in the efficiency of teamwork processes (88%), reduction of errors in the administration of medications to patients (83%), improvement in overall treatment quality (83%), and greater care efficiency (81%). Among nurses, the evaluation of the impact of the implementation or use of electronic systems was relatively better: nine out of ten agreed that there had been an improvement in the efficiency of teamwork processes (94%), greater care efficiency (91%), and improvement in overall treatment quality (88%). Nurses also broadly agreed that the use of electronic systems had resulted in better diagnostic decisions (86%) and reductions in unnecessary or duplicated tests (84%).

CHART 19

PHYSICIANS BY PERCEIVED IMPACT OF THE USE OR IMPLEMENTATION OF ELECTRONIC SYSTEMS (2019)

Total number of physicians (%)





CHART 20

NURSES BY PERCEIVED IMPACT OF THE USE OR IMPLEMENTATION OF ELECTRONIC SYSTEMS (2019)*Total number of nurses (%)***Final considerations: agenda for public policies**

ICT infrastructure in healthcare facilities has advanced in recent years, as shown by the results of the ICT in Health 2019 survey. However, although use of ICT is universal in the private system, it has not reached the same level among facilities in the public system. Disparities among geographic regions still remain, with the North and Northeast being the most affected. As the premise of policies that incentivize more complex uses of ICT in health, it is of strategic importance to provide infrastructure to the locations that are farther from large urban centers and implement quality measurements of these connections.

The unique pandemic situation that the world has been going through since early 2020 has even more strongly highlighted inequalities in access to technologies but has also revealed the urgency of implementing digital health and the need to computerize public services. The characteristic of this period has required the development of innovative actions in health systems, such as the creation of new apps that can help self-assessment of citizens and integration among the different levels of health care. Furthermore, it is urgent to provide access to information systems that are integrated and coordinated among states, municipalities and other health-related organizations, that monitor citizens in risk groups and in more vulnerable areas, and search actively for possible infected persons, in addition to disseminating information about the new disease and the situation of the pandemic in the country.

In this regard, it is essential to monitor the implementation of connectivity strategies, such as the Conecte SUS program, developed by Datasus and consisting of the National Health Data Network and Healthcare Computerization program. This enables the exchange of information among electronic health record systems

and the creation of strategies to assist in self-assessment of COVID-19 symptoms, as well as the dissemination of notifications of infection. At the local level, several local governments across the country have been developing apps that allow for distance consultations and monitoring of patients in the public healthcare system.

Another important step involves the regulation of telehealth in the country, which is currently still carried out on an emergency basis by the Ministry of Health, authorizing physicians to use telemedicine tools to guide, refer and monitor individuals with suspected or mild cases of COVID-19. Restricted to the pandemic period, this regulation officially included teleconsultations in the national COVID-19 clinical protocol in the country's healthcare context, resulting in the adoption of telehealth call centers (Sarti et al., 2020).

The potential benefits created by expanding the use of telehealth tools point to the importance of reviewing the validity of this care protocol beyond the pandemic period in the country to include the entire healthcare system. To become a reality, this will require massive investments aimed at making ICT universal in all public healthcare facilities, considering the different levels of care.

It is also necessary to consider the potential risks to patient information security and privacy caused by rapid expansion of use of technologies in health emergencies. Digital surveillance through tracking citizens via smartphone apps and the use of geolocation and facial recognition must follow specific regulations and pay attention to the ethical dimensions of their use, so that the data are not used for purposes other than personal or collective health. The survey results also indicate that public policies can encourage the adoption of documents, strategies and tools to protect patient health records, which are potential targets of data theft because they are large databases of documentary information.

The advancement of ICT in the health area and the expansion of digital health must be understood as a necessary and urgent public policy that needs to be applied to improve the conditions of access to and quality of health care, the privacy of patient data, and access to disease prevention information, promoting the well-being of the population.

References

- Bashshur, R., Doarn, C. R., Frenk, J. M., Kvedar, J. C., & Woolliscroft, J. O. (2020, maio 6) *Telemedicine and the COVID-19 pandemic, lessons for the future*. Retrieved on August 15, 2020, from <http://doi.org/10.1089/tmj.2020.29040.rb>
- Brazilian General Data Protection Law – LGPD. (2018). Law No. 13709 of August 14, 2018. Provides for the processing of personal data, including in digital media, by individuals or companies of public or private law, with the goal of protecting the fundamental rights of freedom and privacy and the free development of the personality of individuals. Brasília, DF. Retrieved on August 15, 2020, from http://www.planalto.gov.br/ccivil_03/_Ato2015-2018/2018/Lei/L13709.htm
- Brazilian Internet Steering Committee – CGI.br. (2020a). *Survey on the use of information and communication technologies in Brazilian enterprises: ICT Enterprises 2019*. São Paulo: CGI.br.
- Brazilian Internet Steering Committee – CGI.br. (2020b). *Survey on the use of information and communication technologies in Brazilian schools: ICT in Education 2019*. São Paulo: CGI.br.
- Brazilian Internet Steering Committee – CGI.br. (2020c). *Survey on the use of information and communication technologies in Brazilian households: ICT Households 2019*. São Paulo: CGI.br.
- Brazilian Internet Steering Committee – CGI.br. (2020d). *Painel TIC COVID-19: Pesquisa sobre o uso da Internet no Brasil durante a pandemia do novo coronavírus: Atividades na Internet, Cultura e Comércio Eletrônico*. São Paulo: CGI.br.
- Brazilian Internet Steering Committee – CGI.br. (2020e). *Survey on the use of information and communication technologies in the Brazilian public sector: ICT Electronic Government 2019*. São Paulo: CGI.br.
- Brazilian Ministry of Health – MS. (2020a). *Aplicativo Coronavírus-SUS vai alertar contatos próximos de pacientes com Covid-19*. Retrieved on August 15, 2020, from <https://www.saude.gov.br/noticias/agencia-saude/47292-aplicativo-coronavirus-sus-vai-alertar-contatos-proximos-de-pacientes-com-covid-19>
- Brazilian Ministry of Health – MS. (2020b). *Protocolo de manejo clínico do coronavírus (COVID-19) na atenção primária à saúde*. Retrieved on August 15, 2020, from <https://saude.rs.gov.br/upload/arquivos/202004/14140606-4-ms-protocolomanejo-aps-ver07abril.pdf>
- Brazilian Ministry of Health – MS. (2017). *Estratégia de Saúde Digital para Brasil*. Retrieved on August 15, 2020, from https://saudedigital.saude.gov.br/wp-content/uploads/2020/02/Estrategia-e-saude-para-o-Brasil_CIT_20170604.pdf
- Caetano, R., Silva, A. B., Guedes, A. C. C. M., Paiva, C. C. N., Ribeiro, G. R., Santos, D. L., & Silva, R. M. (2020). Desafios e oportunidades para telessaúde em tempos da pandemia pela COVID-19: Uma reflexão sobre os espaços e iniciativas no contexto brasileiro. *Cadernos de Saúde Pública*, 36(5), e00088920.
- Caffery, L. J., Farjian, M., & Smith, A. C. (2016). Telehealth interventions for reducing waiting lists and waiting times for specialist outpatient services: A scoping review. *Journal of Telemedicine and Telecare*, 22(8), 504–512.
- Dorsey, E. R., & Topol, E. J. (2020). Telemedicine 2020 and the next decade. *Lancet*, 395(10227), 859.
- Dunlop, C., Howe, A., Li, & D., Allen, L.N. (2020) The coronavirus outbreak: the central role of primary care in emergency preparedness and response. *BJGP Open*, 4(1).

Greenhalgh, T., Wherton, J., Shaw, S., & Morrison, C. (2020). Video consultations for COVID-19. *BMJ*, 368(m998).

Guañes, P. C. V. (Org.) (2018). *Marcos legais nacionais em face da abertura de dados para pesquisa em saúde: Dados pessoais, sensíveis ou sigilosos e propriedade intelectual*. Rio de Janeiro: Fiocruz.

Holden, R. J., Binkheder, S., Patel, J., & Viernes, S.H.P. (2017). Best practices for health informatician involvement in interprofessional health care teams. *Applied Clinical Informatics*, 9(1), 141-148.

Janett, R. S., & Yeracaris, P. P. (2020). Electronic Medical Records in the American Health System: challenges and lessons learned. *Ciência & Saúde pública*, 25(4), 1293-1304.

Law No. 13989, of April 15, 2020. (2020). Provides for the use of telemedicine during the crisis caused by the coronavirus (SARS-CoV-2). Brasília, DF. Retrieved on August 15, 2020, from http://www.planalto.gov.br/ccivil_03/_ato2019-2022/2020/Lei/L13989.htm

Mann, D. M., Chen, J., Chunara, R., Testa, P. A., & Nov, O. (2020). COVID-19 transforms health care through telemedicine: Evidence from the field. *Journal of the American Medical Informatics Association*, 27(7), 1132-1135.

National Education and Research Network – RNP. (2020). *Aberta a segunda chamada para a conexão de postos de saúde de todo o país*. Retrieved on August 15, 2020, from <https://www.rnp.br/noticias/aberta-segunda-chamada-para-conexao-de-postos-de-saude-de-todo-o-pais>

Ministério da Saúde – MS. (2020b). *Protocolo de manejo clínico do coronavírus (COVID-19) na atenção primária à saúde*. Recuperado em 15 agosto, 2020, de <https://saude.rs.gov.br/upload/arquivos/202004/14140606-4-ms-protocolomanejo-aps-ver07abril.pdf>

Ohannessian, R., Duong T.A., & Odone, A. (2020). Global telemedicine implementation and integration within health systems to fight the COVID-19 pandemic: A call to action. *JMIR Public Health Surveill*, 6(2), e18810.

Ordinance No. 467, of May 20, 2020. (2020). Provides for, on an exceptional and temporary basis, the actions of telemedicine, with the goal of regulating and operationalizing measures to cope with the international public health emergency as established in Article 3 of Law No. 13.979, of February 6, 2020, due to the COVID-19 pandemic. Brasília, DF. Retrieved on August 15, 2020, from <http://www.in.gov.br/en/web/dou/-/portaria-n-467-de-20-de-marco-de-2020-249312996>

Ordinance No. 1434, of May 28, 2020. (2020). Institutes the Conecte SUS program and alters Consolidation Ordinance No. 1/GM/MS, of September 28, 2017, to institute the National Health Data Network, and provides for the adoption of interoperability standards in health. Brasília, DF. Retrieved on August 15, 2020, from <https://rnds.saude.gov.br/wp-content/uploads/2020/06/portaria-n%C2%BA-1.434-202.pdf>

















Ordinance No. 2546, of October 27, 2011. (2011). Redefines and expands the Telehealth Brazil Program, now called the National Telehealth Network in Primary Care Program. Brasília, DF. Retrieved on August 15, 2020, from http://bvsmis.saude.gov.br/bvs/saudelegis/gm/2011/prt2546_27_10_2011.html

Pan American Health Organization – PAHO. (2020a). *COVID-19 Factsheets: Electronic Health Records (EHR) and Interoperability: Understanding two key concepts for a better Public Health response*. Retrieved on August 15, 2020, from <https://iris.paho.org/handle/10665.2/52003>

- Pan American Health Organization – PAHO. (2020b). *Why Data Disaggregation is key during a pandemic*. Retrieved on August 15, 2020, from <https://iris.paho.org/handle/10665.2/52002>
- Pinheiro, P. P. (2018). *Proteção de dados pessoais: Comentários à Lei n. 13.709/2018 (LGPD)* [E-book]. São Paulo: Saraiva Educação.
- Portnoy, J., Waller, M., & Elliott, T. (2020). Telemedicina na era da COVID-19. *The Journal of Allergy Clinical Immunology: In Practice*, 8(5), 1489-1491.
- Santos, R. V., & Terra, R. (2020). A Governança de tecnologia da informação em hospitais melhorando os resultados estratégicos. *Journal of Health Informatics*, 10(2), 64-68.
- Sarlet, G. B. S., & Molinaro, C. A. (2019). Questões tecnológicas, éticas e normativas da proteção de dados pessoais na área da saúde em um contexto de Big Data. *Direitos Fundamentais & Justiça*, 13(41), 183-212.
- Sarti, T. D., Lazarini, W. S., Fontenelle, L. F., & Almeida, A. P. S. C. (2020). Qual o papel da Atenção Primária à Saúde diante da pandemia provocada pela COVID-19?. *Epidemiologia e Serviços de Saúde*, 29(2), e2020166.
- Silva, E. (2017). A telessaúde e seus impactos na formação continuada dos profissionais de saúde em rede. *Em Rede – Revista de educação a distância*, 4(1), 116-129.
- Siqueira, L.S., & Hoch, P.A. (2019). Os dados pessoais e a proteção de dados de saúde: análise a partir de iniciativas de e-Saúde. *Congresso Internacional de Direito e Contemporaneidade*, Rio Grande do Sul, RS, Brasil.
- Sousa, J. H. Jr., Raasch, M., Soares, J. C., & Ribeiro, L. V. H. A. S. (2020). Da desinformação ao caos: uma análise das fake news frente à pandemia do coronavírus (COVID-19) no Brasil. *Cadernos de Prospeção*, 13(2), 331-346.
- Spagnoli, J. A., & Soares, M. N. (2020). *O uso da Inteligência Artificial na nova pandemia SARS-COV-2 e a responsabilidade civil médica e os impactos na nova LGPD*. Retrieved on August 15, 2020, from <https://blog.vendruscolospagnoli.com.br/o-uso-da-inteligencia-artificial-na-nova-pandemia-sars-cov-2-e-a-responsabilidade-civil-medica-e-os-impactos-na-nova-lgpd/>
- Stoeger, K., & Schmidhuber, M. (2020). The use of data from electronic health records in times of a pandemic: a legal and ethical assessment. *Journal of Law and the Biosciences*, 7(1).
- Sutton, R. T., Pincock, D., Baumgart, D. C., Sadowski, D. C., Fedorak, R. N., & Kroeker, K. I. (2020). An overview of clinical decision support systems: Benefits, risks, and strategies for success. *npj Digit. Med.*, 3, 17.
- Tunes, S. (2020, abril 14). Inteligência artificial contra a COVID-19. *Revista Pesquisa Fapesp*. Retrieved on August 15, 2020, from <https://revistapesquisa.fapesp.br/inteligencia-artificial-contra-a-covid-19/>
- World Health Organization – WHO. (2020). *Coronavirus disease 2019 (COVID-19): Situation report 51*. Retrieved on August 15, 2020, from https://www.who.int/docs/default-source/coronaviruse/situation-reports/20200311-sitrep-51-covid-19.pdf?sfvrsn=1ba62e57_10

The background is a light teal color filled with various white geometric shapes and charts. These include bar charts, line graphs, pie charts, hexagons, circles, and arrows. Some elements are labeled with numbers like 01, 02, 03, 04, 05, 06, 07, 08, 09, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 40, 41, 42, 43, 44, 45, 46, 47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 57, 58, 59, 60, 61, 62, 63, 64, 65, 66, 67, 68, 69, 70, 71, 72, 73, 74, 75, 76, 77, 78, 79, 80, 81, 82, 83, 84, 85, 86, 87, 88, 89, 90, 91, 92, 93, 94, 95, 96, 97, 98, 99, 100. There are also some text labels like 'ARTICLES', '100%', '50%', '25%', '15%', '10%', '5%', '0%', '1%', '2%', '3%', '4%', '5%', '6%', '7%', '8%', '9%', '10%', '11%', '12%', '13%', '14%', '15%', '16%', '17%', '18%', '19%', '20%', '21%', '22%', '23%', '24%', '25%', '26%', '27%', '28%', '29%', '30%', '31%', '32%', '33%', '34%', '35%', '36%', '37%', '38%', '39%', '40%', '41%', '42%', '43%', '44%', '45%', '46%', '47%', '48%', '49%', '50%', '51%', '52%', '53%', '54%', '55%', '56%', '57%', '58%', '59%', '60%', '61%', '62%', '63%', '64%', '65%', '66%', '67%', '68%', '69%', '70%', '71%', '72%', '73%', '74%', '75%', '76%', '77%', '78%', '79%', '80%', '81%', '82%', '83%', '84%', '85%', '86%', '87%', '88%', '89%', '90%', '91%', '92%', '93%', '94%', '95%', '96%', '97%', '98%', '99%', '100%'.

ARTICLES



National health data network: Interoperability experience in the healthcare network

Jacson Venâncio de Barros¹, Henrique Nixon Souza da Silva², Roberta Massa Baptista³, Frank James da Silva Pires⁴ and Juliana Pereira de Souza-Zinader⁵

Introduction

Due to technological advances, the value of information, the accelerated pace of change, and globalization, a new information era has opened up in the realm of health and is currently in full swing. This is partly because of the overall adoption of Electronic Health Records (EHR) in recent years and growing interest in the analysis and management of these records (Raghupathi & Raghupathi, 2014). Considering that patients often receive medical treatment from different professionals and various healthcare facilities, information availability and sharing are essential for the present and ongoing care of these individuals.

The World Health Organization (WHO) has argued that access to patient-centered health information is a global need and must be prioritized (World Health Organization [WHO], 2019). Other initiatives have included broadening these

¹ Director of the Department of Health Informatics of the Unified Health System, of the Executive Secretariat of the Ministry of Health (Datusus/SE/MS), master's degree in medical science from the University of São Paulo (USP) Medical School and PhD from the Department of Medical Informatics of the USP Medical School.

² General coordinator of Information and Operations Systems of Datusus, undergraduate degree in computer networks and a specialization in information security from the University of Brasília (UnB).

³ General coordinator of ICT Governance and Project Management of Datusus, undergraduate degree in hospital administration from the São Camilo University Center. Specialization in health quality management from the Albert Einstein Hospital Teaching and Research Institute and executive master's degree student in health management from the Getúlio Vargas Foundation (FGV).

⁴ General Coordinator of Infrastructure of Datusus, undergraduate degree in information systems and information technology analyst at the Ministry of the Economy. Doing a specialization in health informatics at the Sírio-Libanês Teaching and Research Institute.

⁵ General Coordinator of Innovation in Digital Systems of Datusus (ceded server) and adjunct professor at the Institute of Informatics of the Federal University of Goiás (UFGO). PhD in sciences from the graduate studies program in bioengineering interunits (São Carlos School of Engineering, Ribeirão Preto Medical School and Chemistry Institute of São Paulo, of USP).

intergovernmental discussions, such as the Global Digital Health Partnership⁶ (GDHP), whose studies have strengthened the hypothesis that global alignment and international interoperability will only be achieved through the use of common standards (Global Digital Health Partnership [GDHP], 2019).

Resolution WHA71-7, approved in 2018 at the 71st World Health Assembly of WHO, updated the guidelines and terms related to the use of information technology in the context of health care. It addresses the interconnectivity of digital technologies and cyberinfrastructure; the collection, management and evaluation of health data and information; the robustness of the enabling environment, in line with established good practices, while considering the sustainability of innovations; and their feasibility, scale-up, and inclusivity with health information and communication technologies (ICT).

However, to achieve these expectations, there are challenges, and much still needs to be done to overcome them, since there is no universal standard for continuity of care, standardized clinical processes are lacking, a lot of the data is captured incomplete and is of low quality, there is no consensus on the taxonomies that represent the patient's entire journey, and there are different means of financing the service, etc. (GDHP, 2019).

The Unified Health System (SUS) is widely recognized as a model for universal health coverage, one of the UN Sustainable Development Goals (SDGs) for 2030⁷. It accounts for approximately 75% of health care in Brazil, with the rest covered through private plans.

Similar to what is taking place in other countries, an increased number of healthcare facilities, whether public or private, have invested resources in digitizing their medical information and recognize the advantages of using this data (Bittencourt, Camacho, & Carmo Leal, 2006; Lourenção & Ferreira, 2016). However, there are many difficulties, since only a small portion of facilities have electronic records of their transactions (Brazilian Internet Steering Committee [CGI.br], 2019). Therefore, access to medical records often involves working with paper records (CGI.br, 2018). In countries such as Germany, Australia, and Israel, 100% of their medical professionals have access to electronic records, compared to approximately 59% in the United States and Canada (Heart, Ben-Assuli, & Shabtai, 2017).

To address these challenges, Brazil has tried to create mechanisms to enable sharing of health information, particularly Ordinance No. 2073/2011. However, two initiatives (Electronic Health Records - EHR and the Primary Health Unit Investment Plan - PHUIP) were not implemented. In 2019, with the establishment of new directions and based on lessons learned in recent years, it was decided to implement an innovative project with a focus on two fronts: i) creation of a technological environment that functions as a network and has a national approach to enable information sharing; and ii) improvement of primary care activities to ensure health record quality (Sousa, Cielo, Gomes, Oliveira, & Costa, 2019).

⁶ More information on GDHP's website. Retrieved on May 25, 2020, from <https://www.gdhp.org>

⁷ More information on the website of the United Nations in Brazil. Retrieved on June 2, 2020, from <https://nacoesunidas.org/pos2015/agenda2030/>

In this context, the present article presents the journey toward the creation and management of the National Health Data Network (Ordinance MS No. 1434/2020). The network is a complex, cloud-based platform, at the core of which is the use of emergent technologies, which will enable consolidation of patient-centered data in the healthcare context. It will also allow for interchange and interoperability, providing healthcare professionals and managers with another support tool for continuity of care and the public healthcare vision, in addition to empowering citizens by giving them access to their own clinical history.

The expectation of the Ministry of Health is that these actions, combined with the adoption of best technological practices and international standards, will promote the creation of a single patient-centered health record, considering it as an integral part of Conecte SUS, a federal government program whose mission is to implement the first stage of the Digital Health Strategy for Brazil.⁸

The main features of the solution

Using previous initiatives as a basis, it was necessary to design a proposal that would be flexible and scalable. It needed to be flexible because there was no totally ready-made design or similar proposal that would have made benchmarking possible, and because changes would definitely be necessary during its implementation. And it needed to be scalable because, given the volume of data and number of players involved in the data generation and capture process, the project would need to have the means to easily allow for expansion. These factors were preponderant in the decision to use cloud-based solutions (Almutiry, Wills, Alwabel, Crowder, & Walters, 2013).

The information to be shared and made available includes clinical appointments, hospitalizations, tests performed, medications dispensed, and vaccines given. This set of information is called the Minimum Data Set (MDS), because most systems already have this information electronically registered, due to the need for accountability in national information systems (Barros, 2008). The MDS enables moving forward with implementation and, at the same time, focusing on the computerization of healthcare facilities.

It was decided to use open technologies that could be easily replicated on any cloud platform. The definition of technological components was based on international experiences. The issue of security was also addressed and, for this reason, a technology was adopted that stands out for its use in the digital economic realm. It was opted to use blockchain, a sequence of blocks that contains a complete list of records from a certain transaction. Characteristics such as decentralization, persistence, anonymization and auditability ensure security and traceability of events, which are necessary conditions for sharing health information (Zheng, Xie, Dai, Chen, & Wang, 2017).

⁸ More information on the official website of the Digital Health Strategy for Brazil. Retrieved on May 25, 2020, from <https://saudedigital.saude.gov.br/a-estrategia-brasileira/>

In view of the size of Brazil, it was suggested to use a network architecture, composed of a set of virtual containers⁹, and designed to encompass the interconnected federative units. The containers will be responsible for collecting secure information and making it available to health service providers and municipal, state and federal managers, in addition to allowing citizens to access their clinical history, and thereby enable greater control and monitoring of the evolution of their health information.

Technological aspects

The National Health Data Network can be defined as a digital repository of retrospective, simultaneous and prospective patient information. It should be available in different healthcare facilities, making it necessary to use standards for defining not only how information is structured and represented but also how it can be retrieved and shared among the systems in use.

In the 1990s, even though Electronic Health Records (EHR) demonstrated their efficiency and quality, it was necessary to find a solution to the problem of information silos, which are marked by disorganization and storage in various formats – office files, vaccination portfolios – and, when digitized, make it virtually impossible to trace the history of patients and share information with other healthcare professionals. The solution lies in interoperability of medical records, but also involves the problems of longitudinal data analysis and monitoring of patients during healthcare stages. Record standards are necessary for consistent identification of patients and data security. In addition, structural and semantic standardization generated by interoperability can provide various benefits to systems, such as prescription of medications, integration of lab test results, along many other resources (Kuperman, 2011).

Various authors have explored the idea of using agents in the healthcare context to provide interoperability. More recently, some authors have explored blockchain, proposing strategies to improve the mobility and security of EHR by adopting safe and reliable mechanisms for accessing sensitive data about an individual's health (Isern & Moreno, 2016; Wimmer, 2014). Blockchain stores the history of interactions between patients and healthcare agents, together with links to EHR that contain detailed descriptions of each interaction. A hash from the medical record is also stored in the block, so that the fidelity of the content can be easily verified.

When entering into contact with patients, healthcare agents must be accredited in an appropriate software tool in order to retrieve health data via blockchain. Multidisciplinary health teams can request right of access to a patient's data, who must explicitly authorize it, except in cases of break the glass or when configured for an opt out strategy.

A relevant characteristic of blockchain technology is smart contracts, which are responsible for ensuring that the business rules involved in digital transactions are enforced, unlike traditional solutions. They also ensure return of information only

⁹ Containers are compartments containing a number of technological components and data.

to authorized actors who are in compliance with the various laws on information access and confidentiality. Also in this context, structuring of information facilitates scalability of nodes participating in the network, reducing the need for centralized storage, while also guaranteeing interoperability.

In the architecture, metadata will be used in the ledger and distributed among the various participants in the network. In turn, clinical documents will be handled in private data collection, in order to guarantee the privacy and cost-effectiveness of document storage. Since they will only be stored in the custodian org and in a limited structure of backup orgs, there will be no excessive storage of clinical documents. Because it is shared in the ledger, the patient's timeline will be accessible by any org, which will facilitate the patient's consultations in healthcare facilities. The data will be trafficked and stored according to the Fast Healthcare Interoperability Resources (FHIR) standard, in which more than 2,000 existing medical records in the country will be included, with the information structured as required by the Digital Health Strategy. Initially, transition microservices will be used, which can convert data sent in composition and diversification of applications (such as Clinical Document Architecture - CDA), open electronic health records (OpenEHR), and FHIR.

Using the FHIR standard for transporting and storing clinical data, the Ministry of Health defines the necessary infrastructure for the evolution of health care with the prospect to use data analytics and Artificial Intelligence (AI) strategies. The standard should be used together with the structuring of information, enabling the use of data lake and AI strategies in the future.


Implementation strategy

The National Health Data Network was created in accordance with the guidelines of the Digital Health Strategy, based on the National Health Information and Informatics Policy (Ordinance MS No. 589/2015) and the document e-Health Strategy for Brazil (Resolution No. 19/CIT/2017). The work fronts involved in its development can be found in the Action, Monitoring and Assessment Plan of the Digital Health Strategy 2019-2020¹⁰. Figure 1 represents the analytical structure of the program.

¹⁰ More information on the Digital Health Portal website. Retrieved on June 2, 2020, from <https://saudedigital.saude.gov.br/wp-content/uploads/2020/04/PAMA-Saude-digital.pdf>

FIGURE 1

MENTAL MAP OF THE DIGITAL HEALTH STRATEGY OF THE MINISTRY OF HEALTH, WITH AN EMPHASIS ON THE CONECTE SUS PROGRAM AND THE NATIONAL HEALTH DATA NETWORK PROJECT



SOURCE: MINISTRY OF HEALTH.

In order to promote information sharing among the healthcare network points, enabling the transition and continuity of care in the public and private sectors, the National Health Data Network was created to establish this desired health information network: a secure and flexible information platform with high availability that will promote ethical data use and permit the emergence of new services, innovation, research and development, which will be beneficial for Brazil.

The strategy for implementing the National Health Data Network started with the pilot project of the Conecte SUS Program in the state of Alagoas. The location was chosen for the diversity of existing situations, mainly in relation to limited infrastructure resources, such as lack of computers and Internet access, and a low rate of electronic health record use¹¹. The scope of the National Health Data Network prioritizes the MDS and seeks to add value to access to information in the clinical history of patients. It was determined that the start of the project in production will include information from two-year legacy databases, such as data from the Outpatient Information System (Sistema de Informações Ambulatoriais - SIA), Hospital Information System (Sistema de Informações Hospitalares - SIH), Health Information System for Primary Care (Sistema

¹¹ In October 2019, when the Conecte SUS pilot program in Alagoas was launched, 883 Family Health Teams used electronic records. In April 2020, Alagoas reported that 35% of the Family Health Team used electronic medical records. Official data taken from SISAB.

de Informação em Saúde para a Atenção Básica - SISAB), and National Immunization Program Information System (Sistema de Informações do Programa Nacional de Imunizações - SI-PNI), among others.

Access to information will initially occur through the Conecte SUS platform¹², with versions for citizens, healthcare professionals and managers. The portal will be the central access point for procedures performed, enabling citizens to monitor their health situation; allowing healthcare professionals to access tests and the clinical history of their patients, aimed at continuity of care; and enabling managers to monitor health indicators.

The Ministry of Health provides the open application programming interface (API) so that software used by healthcare facilities, such as electronic patient records (PEP), can be integrated into the blockchain solution for the National Health Data Network. In addition, two other applications were developed by the Ministry of Health, enabling direct use by citizens (Conecte SUS Citizen – formerly My digiSUS) and healthcare professionals (Conecte SUS Professional). Figures 2 and 3 present images from Conecte SUS Citizen and Professional.

FIGURE 2

CONECTE SUS CITIZEN APPLICATION SHOWS THE RESULTS OF TESTS DONE ON A PATIENT




SOURCE: MINISTRY OF HEALTH.

¹² More information on the Conecte SUS Portal website. Retrieved on May 25, 2020, from <https://conectesus.saude.gov.br/home>

FIGURE 3

IMAGE OF CONECTE SUS PROFESSIONAL, PROVIDING HEALTH PROFESSIONALS WITH INFORMATION FROM A PATIENT'S MEDICAL HISTORY




SOURCE: MINISTRY OF HEALTH.

At present, the dynamic high-risk situation generated by COVID-19 has required vigorous responses from the entire healthcare system, particularly the SUS, in order to coordinate national actions and orchestrate the efforts of states, municipalities and even the supplementary health sector. As a result, the Conecte SUS Program started to prioritize its actions to fully align them with the national priorities for fighting the coronavirus. In the interim, the National Health Data Network has become a structuring element of an ecosystem aimed at meeting the need to fight the new coronavirus.

As shown in Figure 4, this ecosystem includes specific layers for information security, interoperability between systems, health reporting and surveillance processes, mobile applications, and access channels.

FIGURE 4

CARE AND HEALTH DATA ECOSYSTEM FOR COVID-19¹³*“Onion Model” of the National Health Data Network*

* BRAZILIAN GENERAL DATA PROTECTION LAW (LGPD).

SOURCE: MINISTRY OF HEALTH.

With this new direction, the strategy for implementing the National Health Data Network was adjusted, in order to be provided fully and immediately to all the Brazilian states, thereby establishing it as an essential tool for coping with the pandemic. The platform will enable clinical analysis laboratories to send data to the National Health Data Network, which will collect and process this content and make it available to professionals, managers and citizens through the Conecte SUS portal, in a way that is safe and ensures privacy.

Figure 5 presents the components of the National Health Data Network, with an emphasis on the current representation of the MDS, available services, security services, and planned services.

¹³ Conecte SUS Bulletin, Volume 4, Version 2. Retrieved on May 25, 2020, from <https://saudedigital.saude.gov.br/wp-content/uploads/2020/04/Boletim-Conecte-SUS-Vol-04-Abr-2020-v024-002-novo.pdf>

FIGURE 5

COMPONENTS OF THE NATIONAL HEALTH DATA NETWORK

SOURCE: MINISTRY OF HEALTH.

Final considerations

The National Health Data Network was developed to effectively consolidate a platform for health services and information across Brazil, for the benefit of citizens, healthcare professionals and managers.

Particularly worth noting is the integration of new information services, using emerging technologies to extract health knowledge, in addition to offering alternatives such as: telehealth services, consolidation of the use of clinical terminologies, interoperability with the supplementary health sector, and intelligent regulation of health care.

The National Health Data Network is a health information network and will provide a fertile field for innovation in digital health, opening up possibilities for new service models and the supply of quality information, benefiting all the players involved in public health, as well as in the supplementary and private health sectors.

Also in this context, it is proposed that all new developments be supported by this strategy, strengthening interoperability among the various existing systems in the realm of health. Following are some examples: i) disease reporting systems; ii) national electronic prescriptions; iii) regulation systems. However, it is expected that this platform will enable the use of AI, Analytics, Big Data, the Internet of Things, and other technologies for extraction of knowledge and provision of innovative services in line with current and future national and international needs in the global ecosystem.

The National Health Data Network will also act strategically and comprehensively with analysis of cross-referenced and qualified data, enabling execution of short-, mid- and long-term preventive actions focused on health. The network will also help reduce costs and wastage in healthcare services.

Therefore, it is essential that governance of the Digital Health Strategy accompany this evolution and be increasingly collaborative and inclusive. In line with the action proposed by the WHO Global Strategy on Digital Health, Brazil is willing to share its experience and work with countries and organizations to accelerate the digitization of health in the world, as a way of attaining better levels of health care and well-being for citizens by providing reliable information at any time and place for whoever needs it, when they need it.

References

- Almutiry, O., Wills, G., Alwabel, A., Crowder, R., & Walters, R. (2013). Toward a framework for data quality in cloud-based health information system. *International Conference on Information Society (i-Society 2013)*, Toronto, Canadá.
- Azaria, A., Ekblaw, A., Vieira, T., & Lippman, A. (2016). MedRec: Using blockchain for medical data access and permission management. *International Conference on Open and Big Data (OBD)*, Viena, Áustria, 2.
- Barros, J. V. (2008). *Systems of information and evaluation of hospital performance: the integration and interoperability among of hospital data source*. Master's dissertation, School of Medicine of the University of São Paulo, São Paulo, SP, Brazil.
- Bittencourt, S. A., Camacho, L. A. B., & Carmo Leal, M. (2006). Hospital information systems and their application in public health. *Cadernos de Saúde Pública*, 22(1), 19–30.
- Brazilian Internet Steering Committee - CGI.br. (2018). *Survey on the use of information and communication technologies in Brazilian healthcare facilities: ICT in Health 2017*. São Paulo: CGI.br.
- Brazilian Internet Steering Committee - CGI.br. (2019). *Survey on the use of information and communication technologies in Brazilian healthcare facilities: ICT in Health 2018*. São Paulo: CGI.br.
- Global Digital Health Partnership – GDHP. (2019). *Connected health: Empowering health through interoperability*. Retrieved on June 17, 2020, from https://www.gdhp.org/media-hub/news_feed/gdhp-reports
- Heart, T., Ben-Assuli, O., & Shabtai, I. (2017). A review of PHR, EMR and EHR integration: A more personalized healthcare and public health policy. *Health Policy and Technology*, 6(1), 20–25.
- Isern, D., & Moreno, A. (2016). A systematic literature review of agents applied in healthcare. *Journal of Medical Systems*, 40(2), 43.
- Kuperman, G. J. (2011). Health-information exchange: Why are we doing it, and what are we doing? *Journal of the American Medical Informatics Association*, 18(5), 678–682.
- Lourenção, L. G., & Ferreira, C. J. Jr. (2016). Implementation of patient electronic health records in Brazil. *Enfermagem Brasil*, 15(1), 44.
- Ordinance MS No. 589, of May 20, 2015. (2015). Institutes the National Health Information and Informatics Policy (PNIIS). Retrieved on June 17, 2020, from https://bvsms.saude.gov.br/bvs/saudelegis/gm/2015/prt0589_20_05_2015.html
- Ordinance MS No. 1434, of May 28, 2020. (2020). Institutes the ConecteSUS Program and amends Ordinance Consolidation No. 1/GM/MS of 28 September 2017, to institute the National Health Data Network and addresses the adoption of standards for interoperability in health care. Retrieved on June 17, 2020, from http://www.in.gov.br/web/dou/-/portaria-n-1.434-de-28-de-maio-de-2020-*-259414569
- Ordinance MS No. 2073, of August 31, 2011. (2011). Regulates the use of standards for interoperability and health information for health information systems in the realm of the Unified Health System, at the municipal, district, state and federal levels, as well as for private systems and the supplementary health sector. Retrieved on June 17, 2020, from https://bvsms.saude.gov.br/bvs/saudelegis/gm/2011/prt2073_31_08_2011.html
- Raghupathi, W., & Raghupathi, V. (2014). Big data analytics in healthcare: Promise and potential. *Health Information Science and Systems*, 2(1), 3.

Resolution No. 19/CIT, of June 22, 2017. (2017). Tripartite Inter-Manager Committee of the SUS. Approves and makes public the document entitled e-Health strategy for Brazil, which proposes a vision for e-Health and describes the mechanisms that contribute to its incorporation into the Unified Health System (SUS) by 2020. Retrieved on June 17, 2020, from http://www.in.gov.br/materia/-/asset_publisher/Kujrw0TZC2Mb/content/id/19172500/do1-2017-07-13-resolucao-n-19-de-22-de-junho-de-2017-19172419

Sousa, A. N., Cielo, A. C., Gomes, I. C., Oliveira, J. G. Jr., & Costa, M. L. S. (2019). e-SUS AB strategy: Digital transformation in primary care in Brazil. In Brazilian Internet Steering Committee - CGI.br. *Survey on the use of information and communication technologies in Brazilian healthcare facilities: ICT in Health 2018* (pp. 29–38). São Paulo: CGI.br.

Wimmer, H. (2014). *A multi-agent system for healthcare data privacy*. Retrieved on June 17, 2020, from <https://aisel.aisnet.org/cgi/viewcontent.cgi?article=1171&context=amcis2014>

Wood, C., Winton. B., Carter, K., Benkert, S., Dodd, L., & Bradley, J. (2016). *How blockchain technology can enhance EHR operability*. Retrieved on June 17, 2020, from https://www.hyperledger.org/wp-content/uploads/2016/10/ARKInvest_and_GEM_Blockchain_EHR_Final.pdf

World Health Organization - WHO. (2018). Resolution WHA71-7: 71st World Health Assembly. *Resolutions and decisions adopted by the general assembly*. Retrieved on June 17, 2020, from https://www.un-ilibrary.org/united-nations/resolutions-and-decision-adopted-by-the-general-assembly-during-its-seventy-first-session_65be1928-en

World Health Organization - WHO. (2019). *WHO guideline: Recommendations on digital interventions for health system strengthening*. Geneva: WHO.

Zheng, Z., Xie, S., Dai, H., Chen, X., & Wang, H. (2017). An overview of blockchain technology: Architecture, consensus, and future trends. *2017 IEEE International Congress on Big Data (BigData Congress)*, Honolulu, Estados Unidos, 6.

Data protection in telemedicine¹

Analluza Bolivar Dallari²

On March 11, 2020, the World Health Organization (WHO) classified the disease caused by the new coronavirus, COVID-19, as a pandemic. This means that the virus is propagating on every continent and oligosymptomatic cases are occurring, which makes identification difficult. The new coronavirus is part of a family of viruses that cause respiratory infections and was detected on December 31, 2019, after cases were recorded in China. Telemedicine – a resource that enables remote health care, using technology as the point of contact between patients and physicians – is an efficient method to help combat the pandemic. Modern, efficient, and permanent regulations are still lacking in Brazil. The Resolution CFM No. 1643, of the Federal Council of Medicine (CFM), which is outdated but currently in effect, was published on August 26, 2002, and defines the provision of these services as “the exercise of medicine through the use of interactive audiovisual communication methodologies and data for the purpose of health care, education and research”.

Brazil is facing a public health emergency and, in view of Law No. 13979/2020, which addresses measures to cope with the emergency arising from the new coronavirus, telemedicine has been legally authorized, in its totality, to respond to the situation, without any need for initial in-person consultations. It is an important method that could help prevent the spread and transmission of the virus by preventing the overloading of public and private health services that result from unnecessary hospital and emergency room visits.

¹ This article is an updated edition of an article published by the author on March 19, 2020, entitled “Data protection in telemedicine during the new coronavirus.” Retrieved on May 18, 2020, from <https://www.conjur.com.br/2020-mar-19/analluza-dallari-protecao-dados-telemedicina-tempos-virus>. At the conclusion of this edition of the ICT in Health 2019 survey, on August 29, 2020, Brazil had 3,846,153 cases and 120,462 deaths.

² Lawyer working in the area of health and data protection. PhD and master’s degree in international and comparative law from the Faculty of Law of the University of São Paulo (USP), in addition to a specialization in contract law from the Getúlio Vargas Foundation (GVLaw). Currently works as a lawyer in a multinational company that provides telemedicine services globally.

On March 19, 2020, in response to the then Minister of Health, Luiz Henrique Mandetta, the Federal Council of Medicine issued Official Notice CFM No. 1756/2020-Cojur, recognizing the possibility of using telemedicine in an ethical manner for as long as the measures to combat the COVID-19 are in effect, “on an exceptional basis and throughout the battle to fight the contagion of COVID-19,” thereby expanding the application of the provisions in Resolution CFM No. 1643/2002 to consider temporary regulations for teleguidance, telemonitoring and teleconsultations.

After this position taken by this independent federal public agency, the Ministry of Health published Ordinance MS No. 467/2020, which addresses, on an exceptional and temporary basis, telemedicine activities to regulate and operationalize measures for confronting the international public health emergency, based on Law No. 13979/2020. It clarifies that telemedicine activities using remote interaction may encompass pre-clinical care, care support, and consultation, monitoring and diagnosis, through information and communication technologies, within the Unified Health System (SUS), as well as in private health care.

In the legislative sphere, the Senate passed Bill No. 696 on March 31, 2020, originating from the Chamber of Deputies, which authorizes the use of telemedicine during the coronavirus epidemic in Brazil – also on an exceptional and temporary basis. The objective is to relieve hospitals and health centers through remote patient consultations, via technological resources such as videoconferencing. Enacted after two vetoes by the president of the Republic, Law No. 13989, published on April 15, 2020, deals with the use of telemedicine during the crisis provoked by the coronavirus (SARS-CoV-2). The president vetoed the provisions allowing the CFM to regulate telemedicine after the pandemic ends, arguing that it should be regulated, at least in general terms, by law. He also vetoed the provision regarding the validity of the issuance of remote medical prescriptions and certificates without a digital signature with an ICP-Brasil certificate.

The current legal environment permits the practice of telemedicine in its totality throughout the duration of this state of public emergency. In any case, no safe path to be followed has been clearly defined ethically or legally, especially in relation to privacy, information security, professional confidentiality, and the responsibility of physicians with regard to the storage and sharing of sensitive health data. This article reflects on data protection in telemedicine during the time of this new coronavirus and discusses some practical aspects that have not been directly addressed in the current legal context, with no intention of fully covering all aspects of the topic.

Contextualizing telemedicine

Under the terms of Law No. 3268/1957, it is the responsibility of the Federal Council of Medicine to control the professional exercise of the category and strive to establish good practices for this activity throughout the country. Resolution CFM No. 2217/2018, drafted by the council, approved the most recent Code of Medical Ethics, which was subsequently put into effect on April 30, 2019. The code established, in Paragraph 1 of Article 37, that “remote medical care, in telemedicine or another method, will be subject to the regulations of the Federal Council of Medicine.” As already noted, although it is outdated, Resolution CFM No. 1643/2002, issued by

the same independent public agency, remains as valid. It defines and controls the provision of telemedicine services, but prohibits the totality of its practice, only allowing the use of videoconferencing during procedures to enable physicians to obtain opinions from colleagues during activities that are always conducted in the presence of physicians alongside patients.

The regulations in effect are clearly out of step with the current technological reality. In 2002, there were no smartphones or voice call applications, nor can the quality of transmission of online information at that time be compared to what is available today. Only 30 days after it was published in the Official Federal Gazette³, the full membership of this independent public agency revoked Resolution CFM No. 2227/2018, which defined and established telemedicine as a means of providing medical services mediated by technology. Following this step backwards, a series of public consultations was held to discuss the topic again. They have already taken place and publication of the new regulatory document by the CFM is pending⁴. It may replace the currently outdated definition of telemedicine, established by Resolution No. 1643/2002.

With the pandemic, and under Law No. 13989/2020, the outlook is still uncertain. As mentioned, the president of the Republic vetoed Article 6 of the bill, which established that the Federal Council of Medicine would regulate telemedicine after the end of the crisis brought on by the coronavirus (SARS-CoV-2). According to the president, once the pandemic ends, medical activities using telemedicine must be regulated, at least in general terms, by law, as understood from Article 5, sections II and XIII of the Federal Constitution. It will likely be the responsibility of the CMF to regulate it afterwards, which the probable new law will establish.

What is certain is that the pandemic – and the legal environment updated by it – has shown that there is no turning back the clock on telemedicine, which in its totality includes pre-clinical care, care support, consultation, and monitoring, diagnosis and prescription, through information and communication technologies, since it is in sync with the advances in digital and electronic technologies that are currently so dynamic and present in people's daily lives.

³ CFM council members revoked Resolution No. 2227/2018, which addresses telemedicine, through Resolution CFM No. 2228/2019, published in the Official Federal Gazette on March 6, 2019. Note published on February 6, 2019. Retrieved on February 14, 2020, from https://portal.cfm.org.br/index.php?option=com_content&view=article&id=28096:2019-02-22-15-13-20&catid=3. It was revoked through Resolution No. 2228/2018, which reestablished the validity of Resolution No. 1643/2002, which had been repealed by Resolution No. 2227/2018. This is an odd situation of reenactment. Paragraph 3 of the Law of Introduction to the Rules of Brazilian Law, wording given by Law No. 12376/2010, to Decree-Law No. 4657/1942, rules that "unless otherwise provided, a repealed law cannot be restored because the repealed law has lost its validity".

⁴ The new rules had not been published by the time this edition of the research was published, at the end of the first half of 2020.

Data protection in telemedicine and medical ethics

Article 5, Section XIII, of the Federal Constitution ensures as a fundamental right the freedom to practice any work, trade, or profession, as long as any qualifications established by law are observed. When exercised in an ethical and legal manner, and respecting the freedom and privacy of patients, telemedicine does not violate the physician-patient relationship, and offers social benefits. Even though it is temporary, Law No. 13989/2020 authorizes its practice, which is understood as the exercise of medicine mediated by technology for the purpose of care, research, disease and injury prevention, and health promotion. However, it is a concise law that does not address practical aspects in depth. It establishes that physicians are responsible for informing patients of all the limitations inherent to the use of telemedicine since it is impossible to perform a physical examination during the consultation. It also recommends that the provision of this service adhere to the normal regulatory and ethical standards of in-person care.

However, Law No. 13989/2020 does not address issues regarding the responsibility of physicians for data protection and information security, whether a secondary registration is needed in the state where the patient who is receiving care through a technological tool is located, or determination of the exact location where the service is provided, for tax purposes.

Adequate preparation of free and informed consent forms to be signed by patients, and constant updating of information security tools by medical companies offering telemedicine services, are aspects that should guide the activity to ensure legal and ethical compliance by companies and to avoid the serious penalties provided for by Article 52 of the Brazilian General Data Protection Law (LGDP) and the Code of Medical Ethics (Law No. 13709/2018; Resolution CFM No. 2217/2018). When evaluating the conduct of professionals, the Regional Council of Medicine can apply the penalties provided for in Law No. 3268/1957.⁵

It is already a reality that technology companies and medical service providers are developing software and digital platforms with solutions aimed at teletriage, teleguidance, teleopinions, teleconsultations with teleprescription, and issuing of second medical opinions through platforms and applications that can also use Artificial Intelligence. They are required to respect the laws regarding privacy and information security, such as the LGPD, Code of Medical Ethics and other pertinent CFM resolutions.

Data obtained during telemedicine consultations must be protected, through appropriate and constantly updated information security measures, to avoid unauthorized access. For this purpose, companies can use resources such as hardware and software vulnerability detection, do regular backups, and perform access controls, both physical and logical (access control with special door locks and biometrics, firewalls, anti-malware and double encryption for databases). Passwords cannot be shared, not even among physicians. An appropriate risk management policy, with

⁵ According to Article 22 of this law, the disciplinary penalties that can be applied by the regional councils to their members are the following: a) confidential and private warning; b) confidential and private censure; c) public censure in an official publication; d) suspension of professional practice for up to 30 days; e) termination of professional practice, ad referendum, by the Federal Council.

internal awareness-raising and frequent training, could help prevent the risk of security incidents caused internally through negligence or even willful misconduct.⁶

For issuing prescriptions, physicians should use an electronic signature, through a digital certificate issued by the Brazilian Public Keys Infrastructure (ICP-Brasil, A3 model, card or token), thus ensuring the authenticity, integrity and legal validity of documents in a digital format, in accordance with Provisional Measure No. 2200-2/2001⁷. Seventeen certifying authorities are currently accredited by ICP-Brasil, such as the Federal Data Processing Service (Serpro), Caixa Econômica Federal, and the Brazilian Internal Revenue Service.⁸

In this regard, when vetoing Article 2 of Law No. 13989/2020, the president of the Republic argued that the legislative proposal regarding the validity of medical prescriptions presented in a digital format, provided they contain an electronic or digital signature of the professional issuing the prescription, and dispensing with their issuance in a physical format, would not be in the public interest and would generate a health risk for the population. This is because it equalizes the validity and authenticity of a mere digitized document, which would be easy to counterfeit, with an electronic document with a digital signature with an ICP-Brasil certificate, as a suitable format for prescribing special controlled and antimicrobial medications. This could lead to the collapse of the current system for monitoring the sale of controlled medications and lead to increased consumption of opioids and other drugs of this type, in a way that is not in line with the safety and control technical standards of the Brazilian Health Regulation Agency (Anvisa)⁹. Nevertheless, not all drug stores in Brazil, except for the major chains, are capable of validating and dispensing electronic prescriptions, printed or not.

It is understood from Resolution CFM No. 2227/2019¹⁰ that to ensure the fundamental ethical principles in patient relationships, such as respect for medical confidentiality, all consultations should be recorded and stored, with reports sent to patients, and with the agreement and express authorization of patients or their legal representatives – through written and signed free and informed consent forms. However, the legal framework currently in effect does not require the recording and storage of medical care mediated by technology.

The wording of free and informed consent forms given to patients must be very carefully prepared, in order to safeguard the rights established under Article 18 of the

⁶ The author notes the collaboration of Fernanda Brandão, a quality and information security analyst, for clarification in relation to ISO 27001 (ABNT NBR ISO/IEC 27001:2006), entitled "Information technology – Security techniques – Information security management systems – Requirements," published in October 2005 by the International Organization for Standardization (ISO) and International Electrotechnical Commission (IEC).

⁷ Not converted into law as per Constitutional Amendment No. 32 of September 11, 2001: Article 2 – The provisional measures issued prior to the publication of this amendment remain in force until a subsequent provisional measure explicitly repeals them or until a final decision has been made by the National Congress.

⁸ It is possible to check out the complete list on the website of the National Information Technology Institute (ITI). Retrieved on April 17, 2020 from <https://www.iti.gov.br/icp-brasil/estrutura>

⁹ The possibility of digital signatures with ICP-Brasil certification does not apply to other electronic prescriptions of controlled medications, such as pads for Prescription Notification A (NRA), Special Prescription Notification for Thalidomide, Prescription Notification B and B2 and Special Prescription Notification for Retinoids for systemic use.

¹⁰ Repealed by Resolution CFM No. 2228/2019, restoring the validity of Resolution CFM No. 1643/2002.

LGPD¹¹, and clarify under what circumstances data can be stored by controllers, in a safe way, in light of Article 16, Section I, of the LGPD¹², waiving its deletion. For the purposes of the LGPD¹³, consent is considered to be “a free, informed and unequivocal declaration wherein the patient agrees to the processing of their personal data for a specific purpose.” In the case of services provided online, permission via free and informed consent forms will not be conceded by patients in the form of signatures on physical documents. Therefore, great care must be taken so that they will unequivocally reflect the will of patients, to mitigate the risk of flaws and, consequently, their nullification. Declarations of generic agreement, without restrictions of any kind authorizing the processing of data, are expressly prohibited by law. In the case of processing health data, it should be emphasized that patients are vulnerable, due to the absence of substantial freedom at the time of expressing their agreement, and since it involves data of a very personal and potentially discriminatory nature.¹⁴

The obligation of professional confidentiality also extends to the care teams involved, such as nurses, nutritionists, and pharmacists. No one from the company, apart from physician and these professionals, can access a patient's record without the patient's unequivocal consent. However, the LGPD does provide categorical legal bases for processing sensitive personal data without the consent of the owner-patient.

Paragraph 4 of Article 11 of the LGPD prohibits the communication or shared use among controllers of sensitive personal health data for the purpose of obtaining an economic advantage. However, it allows for exceptions, under hypotheses related to the provision of health services, pharmaceutical assistance and health care, including auxiliary diagnosis and therapy services, provided they are in the interest of the data owners, the practice of risk selection is prohibited, and they enable financial and administrative transactions resulting from the use and provision of these services (Article 11, Paragraph 4, Section II, of the LGPD). Nevertheless, when strictly necessary, communication and sharing must be done in adherence with the principles of end purpose, necessity, transparency, proportionality, security, and non-discrimination.

Some companies, not necessarily health service providers by legal nature, contract telemedicine services as an benefit for their employees. It is important to emphasize

¹¹ Article 18 of the LGPD: The data subject has the right to obtain from the controller, in relation to the data processed by the controller, at any time and upon request: I - confirmation of the existence of the processing operation; II - access to data; III - rectification of incomplete, inaccurate or outdated data; IV - anonymization, blockage or erasure of data that is unnecessary, excessive or not processed in compliance with the provisions of this Law; V - portability of data to other providers of services or products, upon express request, and observing trade and industrial secrets, in accordance with the regulation of the supervisory authority; VI - erasure of personal data processed with the consent of the data subject, except in hypotheses under Article 16 of this Law; VII - information about public and private entities with which the controller has shared data; VIII - information about the possibility of denying consent and the consequences of such denial; IX - revocation of consent under the provisions of § 5 of Article 8 of this Law.

¹² Article 16 of the LGPD: Personal data will be deleted after its processing has been completed, within the sphere and technical limits of the activities, and its preservation will be authorized for the following purposes: I - fulfillment of a legal or regulatory obligation by the controller.

¹³ Article 5, Section XII, of the LGPD.

¹⁴ Article 11 from the Civil Code: With the exception of cases provided for by law, personality rights are non-transferable and cannot be renounced, and their exercise cannot be voluntarily limited.

that the health data of these beneficiary-patients collected during teleconsultations cannot be shared with the employer without legal justification, unless expressly agreed to by the user. It is not uncommon for these companies to expect to receive reports containing minimal data in relation to teleconsultations, whether to assess the service provided and continue providing it to their employees, or to consider a possible dismissal, which would be a risk selection and discriminatory practice. This is prohibited by data protection laws such as the LGPD and the Code of Medical Ethics. Without a legal basis and prior consent, traffic cannot occur even between physicians in the same company.

Article 6 of Law No. 13979/2020 prescribes the following measure: “Sharing of data essential for the identification of infected individuals or suspected coronavirus infection is required between agencies and federal, state, district and municipal public administration organizations, for the exclusive purpose of preventing its propagation.” Paragraph 2 of the same article requires the Ministry of Health to maintain public and up-to-date data on confirmed, suspected or under investigation coronavirus cases, regarding the public health emergency situation, and uphold the right to confidentiality of personal information. This commitment to the privacy of patients is reiterated in Article 13 of Ordinance MS No. 356/2020 of the Ministry of Health. The sharing of this information by private legal entities, when data is requested by health authorities – notifiable diseases – must be done in a way that ensures information security, with full respect for the dignity, human rights and basic freedoms of individuals.

Conclusion

It would be incorrect to believe that telemedicine, conducted ethically and based on confidentiality, privacy, and information security, will replace physicians. However, the practice should be regulated to comprehend the possibilities and limits of engaging in this activity in a way that is more compatible with the current digital reality. According to Chao Lung Wen¹⁵, telemedicine does not endeavor to replace medical practice, but rather to expand the connected health ecosystem and more efficiently integrate the entire health system. This outlook should also be disseminated in medical schools to prepare professionals for this new reality.

There are many advantages to telemedicine when it is carried out ethically and legally. The use of interactive technology resources to enable integrated and humanized care can enhance and intensify access to patients and improve the logistics of the health chain, in addition to promoting health, helping prevent diseases, and protecting patients from exposure to unnecessary risks caused by outings that could be avoided. People can be diagnosed and given guidance without needing to go to an emergency room, where they are vulnerable to more serious infections. It also allows patients to avoid being subjected to invasive and dispensable tests, sparing them from suffering and risks, apart from relieving the burden on the public system and private health operators.

¹⁵ Talk by Professor Chao Lung Wen, of the University of São Paulo Medical School (FMUSP), in the public hearing “Telemedicine, new technologies and innovation in health”, in the Social Security and Family Commission of the Chamber of Deputies, broadcast live on November 28, 2019. Retrieved on February 20, 2020, from https://www.youtube.com/watch?v=8aWHEJg_RWc&t=921s

In the context of the Unified Health System (SUS), telemedicine can help reduce wait times for tests and surgeries and ensure healthcare access to those who need it right away, because it reduces the wait time for emergency services. In this way, emergency rooms and hospitals can fulfill their responsibility to take care of more urgent and complex cases. Telemedicine can also enable transmission of knowledge since specialized practices can be taught to professionals in health services in more distant locations around the country.

To date¹⁶, it is not known how long the state of public emergency decreed due to the international public health emergency arising from the coronavirus will last. It took a pandemic for the Federal Council of Medicine to recognize, even if only temporarily, the importance of telemedicine in its totality as a means to combat dissemination of the new coronavirus and promote social distancing. The Ministry of Health highlighted the need, and the National Congress quickly passed the bill in relation to telemedicine. In a veto message, the president of Brazil stated that, once the current pandemic ends, medical activities using telemedicine must, at least in general terms, be regulated by law and not the CFM. This would indicate that its regulation, done in accordance with the current reality, is inevitable.

¹⁶ Based on the submission date of this article to the ICT in Health 2019 survey, on May 17, 2020.

References

Bill No. 696, of March 31, 2020. (2020). Rules on the use of telemedicine during the crisis caused by the coronavirus (SARS-CoV-2). Brasília, Federal District. Retrieved on May 17, 2020, from <https://www25.senado.leg.br/web/atividade/materias/-/materia/141263>

Brazilian General Data Protection Law - LGPD. Law No. 13709, of August 14, 2018. (2018). This law addresses the processing of personal data, including in digital formats, by individuals or by public or private legal entities, in order to protect the fundamental rights to freedom, privacy, and free development of the personality of individuals. Brasília, Federal District. Retrieved on June 25, 2018, from http://www.planalto.gov.br/ccivil_03/_Ato2015-2018/2018/Lei/L13709.htm

Constitution of the Federative Republic of Brazil of 1988. (1998). Brasília, Federal District. Retrieved on May 17, 2020, from http://www.planalto.gov.br/ccivil_03/constituicao/constituicao.htm

Law No. 3268, of September 30, 1957. (1957). Regulations concerning the Councils of Medicine, and other provisions. Brasília, Federal District. Retrieved on May 17, 2020, from http://www.planalto.gov.br/ccivil_03/leis/L3268.htm

Law No. 12376, of December 30, 2010. (2010). Amends the summary of Decree-Law No. 4657 of September 4, 1942, in relation to the Law of Introduction to the Rules of Brazilian Law. Brasília, Federal District. Retrieved on May 17, 2020, from http://www.planalto.gov.br/ccivil_03/_Ato2007-2010/2010/Lei/L12376.htm

Law No. 13979, of February 6, 2020. (2020). Provides measures for confronting the international public health emergency arising from the coronavirus responsible for the 2019 outbreak. Brasília, Federal District. Retrieved on May 17, 2020, from http://www.planalto.gov.br/ccivil_03/_ato2019-2022/2020/lei/L13979.htm

Law No. 13989, of April 15, 2020. (2020). Provides for the use of telemedicine during the crisis caused by the coronavirus (SARS-CoV-2). Brasília, Federal District. Retrieved on May 17, 2020, from http://www.planalto.gov.br/ccivil_03/_ato2019-2022/2020/Lei/L13989.htm

Official Notice No. 1756, of March 19, 2020. (2020). Brasília, Federal District. Retrieved on May 17, 2020, from http://portal.cfm.org.br/images/PDF/2020_oficio_telemedicina.pdf

Ordinance MS No. 356, of March 11, 2020. (2020), of the Ministry of Health. Establishes the regulations and operationalization of the provisions of Law No. 13979 of February 6, 2020, which institutes measures to combat the international public health emergency arising from the coronavirus (COVID-19). Retrieved on May 17, 2020, from <http://www.in.gov.br/en/web/dou/-/portaria-n-356-de-11-de-marco-de-2020-247538346>

Ordinance MS No. 467, of March 2020. (2020). On an exceptional and temporary basis, rules on telemedicine activities, in order to regulate and operationalize the measures for combating the international public health emergency arising from the COVID-19 epidemic, provided for in Article 3 of Law No. 13979, February 6, 2020. Brasília, Federal District. Retrieved on May 17, 2020, from http://www.planalto.gov.br/CCIVIL_03/Portaria/PRT/Portaria%20n%C2%BA%20467-20-ms.htm

Provisional Measure No. 2200, of August 24, 2001. (2001). Establishes the Brazilian Public Key Infrastructure (ICP-Brasil), transforms the National Institute of Information Technology into an independent public agency, and institutes other provisions. Brasília, Federal District. Retrieved on May 17, 2020, from http://www.planalto.gov.br/ccivil_03/MPV/Antigas_2001/2200-2.htm

Resolution CFM No. 1643, of August 26, 2002. (2002). Defines the control and provision of services through telemedicine. Brasília, Federal District. Retrieved on May 17, 2020, from <https://sistemas.cfm.org.br/normas/visualizar/resolucoes/BR/2002/1643>

Resolution CFM No. 2217, of November 1, 2018. (2018). Approves the Code of Medical Ethics. Brasília, Federal District. Retrieved on May 17, 2020, from http://www.in.gov.br/materia/-/asset_publisher/Kujrw0TZC2Mb/content/id/48226289/do1-2018-11-01-resolucao-n-2-217-de-27-de-setembro-de-2018-48226042

Resolution CFM No. 2227, of December 14, 2018. (2018). Defines the control of telemedicine as a means of providing medical services mediated by technologies. Brasília, Federal District. Retrieved on May 17, 2020, from <https://sistemas.cfm.org.br/normas/visualizar/resolucoes/BR/2018/2227>

Resolution CFM No. 2228, of March 6, 2019. (2019). Repeals Resolution CFM No. 2227, published in the Official Gazette, February 6, 2019, Section I, p. 58, which defines the control of telemedicine as a means of providing medical services mediated by technologies, and expressly restores the validity of Resolution CFM No. 1643/2002. Brasília, Federal District. Retrieved on May 17, 2020, from <https://sistemas.cfm.org.br/normas/visualizar/resolucoes/BR/2019/2228>

Leveraging Artificial Intelligence to maximize use of Electronic Health Record data

Shamim Nemati¹, Supreeth P. Shashikumar², Fatemeh Amrollahi³, Tsung-Ting Kuo⁴
and Lucila Ohno-Machado⁵

Artificial Intelligence in medicine

In 2007, the Institute of Medicine, which is now the National Academy of Medicine, published *The Learning Healthcare System*, describing a vision for healthcare systems as places where “science, informatics, incentives, and culture are aligned for continuous improvement and innovation, with best practices seamlessly embedded in the delivery process and new knowledge captured as an integral byproduct of the delivery experience” (Olsen, Aisner, & McGinnis, 2007). Over the past decade, a number of trends and technological innovations have brought us closer to this vision of a *continuously learning healthcare system*. First, with the increasing adoption of Electronic Health Records (EHR) and clinical “Big Data” (Luo, Wu, Gopukumar, & Zhao, 2016; Bates, Saria, Ohno-Machado, Shah, & Escobar, 2014), the healthcare sector began to catch up with other industries that effectively leverage data to optimize

¹ Assistant Professor at the University of California San Diego. Ph.D. degree in Electrical Engineering and Computer Science from MIT in 2013. While at MIT, he held a Ruth L. Kirschstein National Research Service Award (NRSA) position at the Brigham and Women's Hospital and Harvard Medical School. Upon completion of his Ph.D. degree, Dr. Nemati joined the Harvard Intelligent Probabilistic Systems group as a James S. McDonnell Foundation (JSMF) postdoctoral fellow in complex systems.

² Research Scientist at the UCSD. Ph.D. degree in Electrical and Computer Engineering from Georgia Institute of Technology in 2020. His Ph.D. research was focused on the development of generalizable machine learning models for prediction of adverse clinical events in the Intensive Care Units (ICUs). His research field is focuses on predictive analytics in intensive care and multidimensional time-series analysis using advanced signal processing and deep learning techniques.

³ Ph.D. student at the UCSD and master's in computer science and Biomedical informatics from Emory University in 2018. During her master's studies, she developed an open-source platform for real-time forecasting of sepsis that was based on multidimensional data extracted from Electronic Health Records (EHR) and Bedside Monitors in HL7 or FHIR format.

⁴ Assistant Professor of Medicine in UCSD Health Department of Biomedical Informatics (DBMI). PhD at National Taiwan University (NTU) in the Institute of Networking and Multimedia. Prior to becoming a faculty member, he was a Postdoctoral Scholar at UCSD DBMI and received the UCSD Chancellor's Outstanding Postdoctoral Scholar Award.

⁵ Medical degree from the University of São Paulo and the Ph.D. degree in medical information sciences and computer science from Stanford University. She is the Associate Dean of Informatics and Technology and the Founding Chair of the Health Department of Biomedical Informatics at UCSD. She is elected to the National Academy of Medicine, the American College of Medical Informatics, the American Institute for Medical and Biological Engineering, and the American Society for Clinical Investigation.

customer satisfaction and revenue. Second, the idea of health information exchange through secure and interoperable infrastructure for data sharing took center stage, partially fueled by the promise of a new digital health industry, which is expected to surpass \$504.4 billion by 2025 (Ugalmugle & Devgire, 2019). Third, the remarkable resurgence of Artificial Intelligence (AI) and its impact on automation resulted in growing interest in applying advanced analytics techniques to a variety of healthcare applications (Patel et al., 2009; Jiang et al., 2017; He et al., 2019).

Early clinical decision support (CDS) systems were knowledge-based, i.e., rules derived from domain experts were implemented in computers and refined over time to assist with clinical decision-making. Examples of such rule-based systems include INTERNIST (Miller, McNeil, Challinor, Masarie, & Myers, 1986), a knowledge base consisting of about 500 disease entities and over 3,000 clinical manifestations, and MYCIN (Shortliffe et al., 1985), an expert system used to identify bacteria causing severe infections, such as bacteremia and meningitis, and to recommend antibiotics, with dosages adjusted for patient body weight. Over the past decade, AI techniques, such as machine learning (ML) and deep learning (DL), have gained increasing attention and application in clinical medicine (Ohno-Machado, 2018a; Dilsizian & Siegel, 2014; Johnson et al., 2016; Ravi et al., 2017; Esteva et al., 2019; Rajkomar et al., 2018; Topol, 2019). In these methodologies, models use digitized data (inputs) to make predictions of specified outcomes (outputs). Clinical data can be collected at varying time intervals (e.g., medication and laboratory data from EHR) or continuously (e.g., vital sign data from remote monitoring sensors). Supervised learning is a large area of ML that involves learning a mapping between data and an output label, such as mortality or hospital readmission. The goal of learning (in the context of ML) is to derive the features (or data representations) that are most predictive of the specific labels under consideration. Given the breadth and richness of patient data that are currently available, ML and DL are able to compute complex interactions or temporal relationships among inputs that bedside clinicians and patients commonly overlook (Shashikumar, Josef, Sharma, & Nemati, 2019).

Indeed, the use of ML to triage patients with acute and chronic diseases has already shown some promising initial results. Sendak et al. (2020) provide a comprehensive review of ML algorithms applied to CDS tasks, with an emphasis on models that have been integrated into clinical workflows. The most common examples of CDS systems include early prediction of sepsis (Shashikumar et al., 2019; Nemati, et al., 2018; Giannini et al., 2019), and acute kidney injury (AKI), (Connell et al., 2019; Tangri et al., 2011), as well as algorithms for emergency department (ED) triage (Levin et al., 2018), prediction of cardiac arrest (Churpek et al., 2016), fall risk assessment for hospitalized patients (Cho, Boo, Chung, Bates, & Dykes, 2019), hospital readmission prediction within 30 days (Hao et al., 2015), and readmission for patients with chronic obstructive pulmonary disease (COPD) (Min, Yu, & Wang, 2019), among others.

While ML methods have provided the community with a wealth of knowledge about how patient care could be improved, a number of challenges have slowed down the broader adoption of such systems in clinical practice. These include: 1) lack of transparency or explanations (“black box”); 2) issues surrounding generalizability and portability of ML algorithms; and 3) data accessibility and patient privacy. In this chapter, some of the potential solutions to these challenges using a real-world implementation study of an ML algorithm for early prediction of sepsis will be reviewed.

A case study of sepsis prediction

Sepsis is among the leading causes of morbidity and mortality in critically ill patients and is the most expensive condition in terms of healthcare spending. The sepsis syndrome occurs when the body's overwhelming response to an infection produces a dysregulated immune response and causes severe tissue damage that may lead to organ failure and death. It is currently one of the critical problems in medicine due to its complexity from the pathophysiological, clinical, and therapeutic viewpoints. Sepsis is a significant cause of hospitalization and is a particularly common problem in intensive care units (ICU), affecting about 25% of admitted patients. The Healthcare Cost and Utilization Project (HCUP) and the Agency for Healthcare Research and Quality (AHRQ) estimated the 2013 annual cost of hospital care for sepsis patients in the United States to be \$24 billion.

Given its complexity, sepsis can be challenging to diagnose; early diagnosis is critical, as demonstrated by a large 2006 study that found that "each hour of delay in antimicrobial administration over the ensuing 6 hours was associated with an average decrease in survival of 7.6%" (Kumar et al., 2006). As such, the major tenet of sepsis care is prompt recognition and initiation of treatments such as antibiotics. However, no clinically validated system exists for accurate, real-time prediction of sepsis onset. Ideally, such a system should also be cleared by the appropriate regulatory agencies to ensure patient safety.


The goal of the Artificial Intelligence Sepsis Expert (AISE) (Nemati et al., 2018) was to enable early recognition of sepsis in adult ICU patients. In particular, the algorithm was trained on 31,000 Emory University ICU patients and validated on 52,000 patients from MIMIC-III, a freely accessible critical care database developed at the MIT Laboratory for Computational Physiology (Johnson et al., 2016). AISE was trained on sepsis labels derived based on the Third International Consensus Definitions for Sepsis and Septic Shock (Sepsis-3) (Seymour et al., 2016). The research team concluded that the tool predicts sepsis 4 to 6 hours in advance (area under the receiver operating characteristic curve – ROC – 95%; confidence interval 0.85-0.88). Given the complexity of critical care, including high-dimensional and longitudinal streams of data and rapidly deteriorating patient states, AISE was designed to produce hourly risk scores that are interpretable by clinical teams. Moreover, to gain wide clinical adoption, the system had to be designed to be generalizable and portable, and to ensure the privacy of patients whose data were used for model training and evaluations, as well as during the real-time implementation of the system.

NEED FOR INTERPRETABILITY

As described earlier, the AISE system was deployed in a production setting to process high-resolution vital signs and laboratory measurements in real time in order to produce prediction scores and warn caregivers of the impending development of sepsis in patients 4 to 6 hours in advance. Physicians will not generally accept a computer-based recommendation unless the clinical basis for that advice is clear. Moreover, recent regulations such as the "right to explanation", mandated by the European Union's General Data Protection Regulation - GDPR (Goodman & Flaxman, 2017), are restricting application of automated decision-making in scenarios where

there are significant effects on end users. For this reason, the AISE team focused on an interpretable class of AI models, which made it possible to inspect which variables were most important in a particular risk calculation for patients. This was achieved by considering a metric known as the “relevance score”, which measures each feature’s contribution to the risk score. Figure 1 depicts an illustrative example of the AISE model’s predictions and the underlying top factors contributing to risk scores (Panel C). This notion of interpretability was further incorporated into a clinician-facing user interface (UI) (Figure 3). Each patient was represented by a single card, which contained the patient’s room number at the top, the sepsis score, and a directional arrow with magnitude representing the change (i.e., delta) in the patient’s sepsis risk score over the past four hours. Additionally, the top three factors contributing to the risk scores were presented on the back of each card, displayed via a single click on the card.

FIGURE 1
AN ILLUSTRATIVE EXAMPLE OF THE AISE ALGORITHM IN ACTION



SOURCE: PREPARED BY THE AUTHORS.


Note: Hourly calculated Sequential Organ Failure Assessment (SOFA) Score, Sepsis-3 criteria for sepsis (Seymour et al., 2016), and the AISE score are shown for one patient in Panel (A). Commonly recorded hourly vital signs are shown in Panel (B). The most significant features contributing to the AISE score (for clarity of presentation, only selected time-points are shown). Notably, around 4 pm on December 20, roughly 8 hours prior to any change in the SOFA score, the sepsis score for this patient starts to increase. The top contributing factors (Panel C) were slight changes in heart rate (HR), respiratory rate (RESP), and temperature (TEMP), given that the patient had surgery in the previous 12 hours with a contaminated wound and was on a mechanical ventilator. Close to midnight on December 21, other factors, such as multiscale entropy of blood pressure time series (BPV1), the Glasgow Coma Scale (GCS), and lactate show abnormal changes. Five hours later, the patient met the Sepsis-3 definition of sepsis. ABX: antibiotics, CultPos/Neg: Culture positive/negative, O2Sat: Oxygen saturation.

NEED FOR GENERALIZABILITY

A key shortcoming of many existing ML and predictive analytics risk scores is their lack of generalizability across institutions and performance degradation within the same institution across time (Kelly, Karthikesalingam, Suleyman, Corrado, & King, 2019). This limited generalizability is due to a number of factors, including differences in local populations, EHR systems, coding definitions, laboratory equipment and assays, as well as variations in clinical and administrative practices. In a recent study aimed at detecting abnormal chest radiographs, the specificity of an ML model at a fixed sensitivity varied widely, from 0.566 to 1.000, across five independent datasets (Hwang et al., 2019; Zech et al., 2018). Similarly, most existing published clinical ML and predictive analytics models are either based on data from a single hospital (Futoma, Hariharan, & Heller, 2017; Henry, Hager, Pronovost, & Saria, 2015) or from multiple hospitals in the same healthcare system (Josef, Ramnath, Malhotra, & Nemati, 2019), where the processes of care are mostly standardized. Although less common, clinical ML models that have been validated across different healthcare systems are sometimes retrained from scratch on every new patient cohort (Nemati et al., 2018; Oh et al., 2018), or, when applied out of the box, often exhibit significant degradation in performance (Bennett et al., 2019).


During the external evaluation, the pretrained AISE model derived from data originating only from the development cohort was fine-tuned on the training subset at the validation site, using 20 iterations of the gradient descent algorithm. The AISE model was then evaluated on the test set of the validation cohort. The purpose of the external evaluation step was to show that the model could be tailored to the characteristics of each local population and could provide accurate predictions. This approach falls under the framework of “transfer learning” in the ML literature, and has been shown to improve prediction performance, as opposed to a model trained from scratch on external cohorts, particularly when only limited data are available for training (Deo, 2015). In this framework, the knowledge gained by solving a classification problem on the development cohort is stored in the weights of the neural network and is carried forward to the target cohort (Figure 2). Learning of an accurate and generalizable classifier on the target cohort can be achieved using fewer training data. This approach has previously been used to fine-tune a neural network model for the detection of diabetic retinopathy in retinal fundus photographs (Gulshan et al., 2016).

FIGURE 2
SCHEMATIC DIAGRAM OF TRANSFER LEARNING



Note: The diagram in Figure 2 shows: (1) A prediction model neural network (such as AISE) is initialized with random weights and is trained using data from the development site. (2) Starting with a pretrained model from the development site, the model weights are fine-tuned (or retrained) using a relatively small amount of training data from the validation site prior to evaluation using the test set of the validation cohort.

FIGURE 3
SEPSIS PREDICTION SOFTWARE PIPELINE



Note: Fast Healthcare Interoperability Resources (FHIR) and Health Level 7 (HL7) standards ensure an interoperable system. Containerization (via Docker technology) enhances portability, and provides a modular design that allows the individual microservices (e.g., local database or predictive analytic service) to communicate via application programming interface (API) calls. Each microservice keeps track of all incoming and outgoing API calls and responses, and produces event logs for quality management and Health Insurance Portability and Accountability Act (HIPAA) compliance purposes. A user interface (UI) displays a ranked list of patients according to their risk of sepsis (as small cards) and enables the clinical team to interact with the system.

NEED FOR INTEROPERABILITY AND PORTABILITY

Complementary to the issue of generalizability of clinical ML models is the requirement of data standardization and access, and the ability to seamlessly move an ML-based software pipeline to a new institution for deployment. Figure 3 illustrates how AISE fulfills these requirements by relying on data standards and exchange protocols such as the Health Level (HL7®) Fast Healthcare Interoperability Resources (FHIR) (Braunstein, 2018) standard framework and software containerization for portability (Saltz et al., 2017). FHIR defines a collection of standards both for storing clinical data (i.e., FHIR resources), and for a set of REpresentational State Transfer (REST) API protocols for the exchange of these resources. The use of containerized microservices removes the need to install distinct applications and their associated dependencies on host machines at various deployment sites. It also allows the AISE system to leverage the inherent scalability and fault tolerance of containerized applications (Sirin Software, 2018; Bernstein, 2014).

NEED FOR MULTIMODAL DATA INTEGRATION

Some important pieces of information are usually recorded only within narrative data (e.g., clinical notes, radiology reports) of EHR systems. These data can be critical for clinical ML, while not being directly available in the structured portion of the data. Ejection fraction (EF) is an important predictor for cardiovascular diseases, yet it may only be recorded in narrative echocardiogram reports. Therefore, clinical natural language processing (NLP) techniques can be used to extract covariates such as EF (Garvin et al., 2012; Patterson et al., 2017) to increase the predictive capability of clinical ML methods. Clinical NLP can be rule-based (i.e., extracting these values using expert-defined rules), ML-based (i.e., training a model using expert-annotated clinical texts), or a combination of both approaches. Examples of clinical NLP systems include MetaMap (Aronson, 2001), cTAKES (Savova et al., 2010), and CLAMP (Soysal et al., 2018). Also, the extraction results from these clinical NLP systems can be combined to further improve extraction performance (Kuo et al., 2016).

NEED FOR PRIVACY AND DATA SECURITY

Fundamental to the analysis of any data related to human subjects is the requirement for patient privacy and data security, which are governed by the Health Insurance Portability and Accountability Act (HIPAA) and the Common Rule in the United States (Annas, 2003) and the General Data Protection Regulation (GDPR) across Europe (Voigt & von demme Bussche, 2017). These regulations and their respective counterparts in different countries are crucial for the confidential handling of protected health information (PHI) and protecting the subjects of biomedical research (Ohno-Machado, 2018b). While open-source algorithms, software, and data are highly desirable to ensure scientific reproducibility and generalizability, the private nature of the data prohibits this approach when PHI is involved.

The AISE platform enforces security measures during deployment by restricting unauthorized access to sensitive data and APIs, and by ensuring that proper access

policies and authentication mechanisms are in place. Containerization and APIs allow for defining single points of access (via predetermined ports) and restricting access to specific microservices. These access policies are defined in advance, and access/audit logs are generated to ensure adherence to predefined policies. Furthermore, this approach minimizes the potential for denial-of-service attacks by ignoring service invocations from unknown sources.

Emerging trends: An example use of blockchain technology


The original bitcoin blockchain technology was developed for cryptocurrencies, but was used in various other applications, including in healthcare (Kuo, Kim, & Ohno-Machado, 2017). A variety of new platforms have been developed in the past decade, and some have already been demonstrated in clinical applications (Kuo, Zavaleta Rojas, & Ohno-Machado, 2019). Its application becomes particularly attractive when a group of institutions, which may trust each other but still like to verify each other's actions, are collaborating. blockchain can play a role in managing data and models. As indicated in the previous section, there are many requirements for an AI system to be successful. blockchain is not a panacea for managing the complex web of data and model transactions needed to enable AI in clinical settings, but it can serve as valuable tool in cases where it is important to have reliable sources of data, metadata and models across a network of collaborating institutions. Transactions that happen across this network need to be easy to inspect and extremely hard to tamper with.

Traditionally, data security is achieved by healthcare institutions through the use of firewalls (access-restricted systems) and strict regulations regarding the breadth and quantity of patient data that can be archived. More recently, encryption protocols have been applied. However, to enable model training and evaluation across multiple institutions, new security and ML paradigms have been developed. In particular, distributed learning (Wu, Jiang, Kim, & Ohno-Machado, 2019; Wang et al., 2013) and blockchain technology (Nakamoto, 2008) were combined to preserve privacy for clinical ML while mitigating security risks (Figure 4). Distributed learning disseminates ML models (i.e., aggregated parameters) instead of patient-level PHI data to other institutions that are collaborating to develop generalizable ML models. However, conventional distributed learning methods require a central server to integrate the ML models, and such a central intermediary can represent a single point of failure (i.e., the whole ML process fails if this central server is down). To mitigate this security risk, blockchain-based privacy-preserving modeling methods (Kuto, Gabriel, Cidambi, & Ohno-Machado, 2020) adopt a peer-to-peer network topology, and their use provides the known benefits of blockchain use, such as immutability, transparency, and ascertainment of data provenance (Kuo et al., 2017).

Additionally, an important feature of newer blockchain technology is the possibility of encoding “smart contracts” (Buterin, 2019). These contracts are extensions of the original blockchain 1.0 technology that recorded transactions but did not record the “rules” or algorithms that permitted these transactions under specific circumstances (i.e., contracts between the parties). blockchain 2.0 technology allows for code that is embedded in the chain to manage transactions, making not only the data but also

the code immutably included in the chain. The immutability property of blockchain technology justifies its application as a distributed ledger to lend users control of their own data, as in the case of managing cross-institution data consent for genetic studies or for electronic health records (Yu, Sun, Wu, & Kuo, 2020), pharmaceutical supply chains to ascertain provenance (Mackey et al., 2019), etc.

FIGURE 4

PRIVACY-PRESERVING CLINICAL ML

SOURCE: KUO & OHNO-MACHADO, 2018.

Note: Figure 4 presents: (A) A conventional approach that only transfers models, not PHI data. To integrate the ML models from each site, this approach requires a central server, which could present a single point of failure (i.e., the whole ML process stops if this server fails). (B) A blockchain solution that is distributed and thus presents no single point of failure. Additionally, the use of blockchain provides immutable, transparent, and source-verifiable recording of the ML models.

Conclusion

The use of AI in clinical medicine was proposed decades ago, but was only enabled when sufficient data, enhanced methods, and efficient technology became available at scale. There is now an increasing number of applications in biomedical research and healthcare that utilize various AI technologies. It is possible to anticipate that AI will become integral to many clinical applications, and that its widespread, seamless utilization will accelerate advancement of healthcare solutions, as well as biomedical discoveries. There are still, however, many areas of possible improvement in order for AI to help clinicians make full use of data from EHR systems to deliver better care. This article presented here an example in which an alert for sepsis can be issued several hours prior to the “official” diagnosis, leading to potential advances in the start of treatment that could result in significant differences in patient outcomes. also It was also discussed that, to harness and realize the power of clinical Big Data and Artificial Intelligence to improve patient care, a number of challenges related

to algorithmic transparency, generalizability, portability, accessibility, and patient privacy have to be overcome. It was shown how the emerging use of blockchain technology can help circumvent these problems. It is possible to remain optimistic that all these challenges will ultimately be addressed by a combination of advances in science, technology and policy, and that AI will be seamlessly integrated into many clinical activities in the near future.

Acknowledgments

SN, SPS, and FA are funded by the National Institutes of Health (NIH) K01ES025445, National Science Foundation (NSF) 1822378, Biomedical Advanced Research and Development Authority HHSO100201900015C, and the Gordon and Betty Moore Foundation GBMF9052.

T-TK is funded by NIH R00HG009680, R01HL136835, R01GM118609, and U01EB023685; UCSD Academic Senate Research Grant RG084150. LO-M is funded by NIH R01HL136835, R01GM118609, U01EB023685, OT2OD026552, and R01HG011066; NSF grant OIA-1937136.

The content is solely the responsibility of the author and does not necessarily represent the official views of the funding agencies. The funders had no role in study design, data collection and analysis, decision to publish, or preparation of the manuscript.

References

- Annas, G. J. (2003). HIPAA regulations — A new era of medical-record privacy? *The New England Journal of Medicine*, 348(15), 1486–1490.
- Aronson, A. R. (2001). Effective mapping of biomedical text to the UMLS Metathesaurus: The MetaMap program. *Proceedings of the AMIA Annual Symposium*, 17–21.
- Bates, D. W., Saria, S., Ohno-Machado, L., Shah, A., & Escobar, G. (2014). Big data in health care: Using analytics to identify and manage high-risk and high-cost patients. *Health Affairs*, 33(7), 1123–1131.
- Bennett, T., Russell, S., King, J., Schilling, L., Voong, C., Rogers, N., . . . Ghosh, D. (2019). Accuracy of the Epic Sepsis Prediction Model in a regional health system. *ArXiv190207276 Cs Stat*. Retrieved on June 17, 2020, from <http://arxiv.org/abs/1902.07276>
- Bernstein, D. (2014). Containers and cloud: From LXC to Docker to Kubernetes. *IEEE Cloud Computing*, 1(3), 81–84.
- Braunstein, M. L. (2018). Healthcare in the age of interoperability: The promise of fast healthcare interoperability resources. *IEEE Pulse*, 9(6), 24–27.
- Buterin, V. (2019). A next generation smart contract & decentralized application platform. *Ethereum White Paper*.
- Cho, I., Boo, E.-H., Chung, E., Bates, D. W., & Dykes, P. (2019). Novel approach to inpatient fall risk prediction and its cross-site validation using time-variant data. *Journal of Medical Internet Research*, 21(2), e11505.
- Churpek, M. M., Yuen, T. C., Winslow, C., Meltzer, D. O., Kattan, M. W., & Edelson, D. P. (2016). Multicenter comparison of machine learning methods and conventional regression for predicting clinical deterioration on the wards. *Critical Care Medicine*, 44(2), 368–74.
- Connell, A., Montgomery, H., Martin, P., Nightingale, C., Sadeghi-Alavijeh, O., King, D. . . . Raine, R. (2019). Evaluation of a digitally-enabled care pathway for acute kidney injury management in hospital emergency admissions. *NPJ Digital Medicine*, 2(1), 1–9.
- Deo, R. C. (2015). Machine learning in medicine. *Circulation*, 132(20), 1920–1930.
- Dilsizian, S. E., & Siegel, E. L. (2014). Artificial intelligence in medicine and cardiac imaging: Harnessing big data and advanced computing to provide personalized medical diagnosis and treatment. *Current Cardiology Reports*, 16(1), 441.
- Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristom, M., Chou, K., . . . Dean, J. (2019). A guide to deep learning in healthcare. *Nature Medicine*, 25(1), 24–29.
- Futoma, J., Hariharan, S., & Heller, K. (2017). Learning to detect sepsis with a multitask gaussian process RNN classifier. *Proceedings of the 34th International Conference on Machine Learning - Volume 70*. Sydney, Australia: JMLR.org, p. 1174–1182. (ICML'17).
- Garvin, J. H., DuVall, S. L., South, B. R., Bray, B. E., Bolton, D., Heavirland, J., . . . Goldstein, M. K. (2012). Automated extraction of ejection fraction for quality measurement using regular expressions in Unstructured Information Management Architecture (UIMA) for heart failure. *Journal of the American Medical Informatics Association: JAMIA*, 19(5), 859–866.

- Giannini, H. M., Ginestra, J. C., Chivers, C., Draugelis, M., Hanish, A., Schweickert, W. D., . . . Umscheid, C. (2019). A machine learning algorithm to predict severe sepsis and septic shock: Development, implementation, and impact on clinical practice. *Critical Care Medicine*, 47(11), 1485–92.
- Goodman, B., & Flaxman, S. (2017). European Union regulations on algorithmic decision-making and a “right to explanation.” *AI Magazine*, 38(3), 50–57.
- Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., . . . Webster, D. R. (2016). Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA*, 316(22), 2402–2410.
- Hao, S., Wang, Y., Jin, B., Shin, A. Y., Zhu, C., Huang, M., . . . Ling, X. B. (2015). Development, validation and deployment of a real time 30 day hospital readmission risk assessment tool in the Maine healthcare information exchange. *PloS One*, 10(10), e0140271.
- He, J., Baxter, S. L., Xu, J., Xu, J., Zhou, X., & Zhang, K. (2019). The practical implementation of artificial intelligence technologies in medicine. *Nature Medicine*, 25(1), 30–36.
- Henry, K. E., Hager, D. N., Pronovost, P. J., & Saria, S. (2015). A targeted real-time early warning score (TREWScore) for septic shock. *Science Translational Medicine*, 7(299), 299ra122.
- Hwang, E. J., Park, S., Jin, K-N., Kim, J. I., Choi, S. Y., Lee, J. H., . . . Park, C. M. (2019). Development and validation of a deep learning-based automated detection algorithm for major thoracic diseases on chest radiographs. *JAMA Network Open*, 2(3), 191095.
- Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., . . . Wang, Y. (2017). Artificial intelligence in healthcare: Past, present and future. *Stroke and Vascular Neurology*, 2(4), 230–243.
- Johnson, A. E. W., Ghassemi, M. M., Nemati, S., Niehaus, K. E., Clifton, D. A., & Clifford, G. D. (2016a). Machine learning and decision support in critical care. *Proceedings of the IEEE, Institute of Electrical and Electronics Engineers*, 104(2), 444–466.
- Johnson, A. E. W., Pollard, T. J., Shen, L., Li-wei, H. L., Feng, M., Ghassemi, M., . . . Mark, R. G. (2016b). MIMIC-III, a freely accessible critical care database. *Scientific Data*, 3, 160035.
- Josef, C. S., Ramnath, V., Malhotra, A., & Nemati, S. (2019). Performance comparison of unit specific and generalizable sepsis prediction models across intensive care units. *SHOCK*, 85–86.
- Kelly, C. J., Karthikesalingam, A., Suleyman, M., Corrado, G., & King, D. (2019). Key challenges for delivering clinical impact with artificial intelligence. *BMC Medicine*, 17(1), 195.
- Kumar, A., Roberts, D., Wood, K. E., Light, B., Parrillo, J. E., Sharma, S., . . . Cheang, M. (2006). Duration of hypotension before initiation of effective antimicrobial therapy is the critical determinant of survival in human septic shock. *Critical Care Medicine*, 34(6), 1589–1596.

- Kuo, T-T., & Ohno-Machado, L. (2018). ModelChain: Decentralized privacy-preserving healthcare predictive modeling framework on private blockchain networks. ArXiv180201746 Cs. Retrieved on August 20, 2020, from <http://arxiv.org/abs/1802.01746>
- Kuo T-T., Kim, H-E., & Ohno-Machado, L. (2017). Blockchain distributed ledger technologies for biomedical and health care applications. *Journal of the American Medical Informatics Association: JAMIA*, 24(6), 1211–1220.
- Kuo, T-T., Rao, P., Maehara, C., Doan, S., Chaparro, J. D., Day, M. E., . . . Hsu, C. N. (2016). Ensembles of NLP tools for data element extraction from clinical notes. *Proceedings of the Annual AMIA Symposium*, 1880–1889. Retrieved on August 20, 2020, from <https://www.ncbi.nlm.nih.gov/pubmed/28269947>
- Kuo, T-T., Zavaleta, Rohas, H., & Ohno-Machado, L. (2019). Comparison of Blockchain platforms: A systematic review and healthcare examples. *Journal of the American Medical Informatics Association: JAMIA*, 26(5), 462–478.
- Kuo, T. T., Gabriel, R. A., Cidambi, K. R., & Ohno-Machado, L. (2020). EXpectation Propagation LOGistic REGression on permissioned Blockchain (ExplorerChain): Decentralized online healthcare/genomics predictive model learning. *Journal of the American Medical Informatics Association: JAMIA*, 27(5), 747–756.
- Levin, S., Toerper, M., Hamrock, E., Hinson, J. S., Barnes, S., Gardner, H., . . . Kelen, G. (2018). Machine-learning-based electronic triage more accurately differentiates patients with respect to clinical outcomes compared with the emergency severity index. *Annals of Emergency Medicine*, 71(5), 565–574.
- Luo, J., Wu, M., Gopukumar, D., & Zhao, Y. (2016). Big data application in biomedical research and health care: A literature review. *Biomed Informatics Insights*, 8, 1–10.
- Mackey, T. K., Kuo, T-T., Gummadi, B., Clauson, K. A., Church, G., Grishin, D., . . . Palombini, M. (2019). ‘Fit-for-purpose?’ – challenges and opportunities for applications of Blockchain technology in the future of healthcare. *BMC Medicine*, 17(1), 68.
- Miller, R. A., McNeil, M. A., Challinor, S. M., Masarie, F. E., & Myers, J. D. (1986). The INTERNIST-1/QUICK MEDICAL REFERENCE project—status report. *The Western Journal of Medicine*, 145(6), 816–22.
- Min, X., Yu, B., & Wang, F. (2019). Predictive modeling of the hospital readmission risk from patients’ claims data using machine learning: A case study on COPD. *Scientific Reports*, 9(1), 362.
- Nakamoto S. (2008). *Bitcoin: A peer-to-peer electronic cash system*. Satoshi Nakamoto Institute.
- Nemati, S., Holder, A., Razmi, F., Stanley, M. D., Clifford, G. D., & Buchman, T. G. (2018). An interpretable machine learning model for accurate prediction of sepsis in the ICU. *Critical Care Medicine*, 46(4), 547–53.
- Oh, J., Makar, M., Fusco, C., McCaffrey, R., Rao, K., Ryan, E. E., . . . Wiens, J. (2018). A generalizable, data-driven approach to predict daily risk of clostridium difficile infection at two large academic health centers. *Infection Control and Hospital Epidemiology*, 39(4), 425–433.
- Ohno-Machado, L. (2018a). Data science and artificial intelligence to improve clinical practice and research. *Journal of the American Medical Informatics Association: JAMIA*, 25(10), 1273.

Ohno-Machado, L. (2018b). Sharing data from electronic health records within, across, and beyond healthcare institutions: Current trends and perspectives. *Journal of the American Medical Informatics Association: JAMIA*, 25(9), 1113.

Olsen, L., Aisner, C., & McGinnis, J. M. (Eds.). (2007). *The learning healthcare system*. Workshop Summary of Institute of Medicine Roundtable on Evidence-Based Medicine. Washington, DC: National Academies Press.

Patel, V. L., Shortliffe, E. H., Stefanelli, M., Szolovits, P., Berthold, M.R., Bellazzi, R., & Hanna, A. (2009). The coming of age of artificial intelligence in medicine. *Artificial Intelligence in Medicine*, 46(1), 5–17.

Patterson, O. V., Freiberg, M. S., Skanderson, M. J., Fodeh, S., Brandt, C. A., & DuVall, S. L. (2017). Unlocking echocardiogram measurements for heart disease research through natural language processing. *BMC Cardiovascular Disorders*, 17(1), 151. Retrieved on August 20, 2020, from <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5469017/>

Rajkomar, A., Oren, E., Chen, K., Dai, A. M., Hajaj, N., Hardt, M., . . . Dean, J. (2018). Scalable and accurate deep learning with electronic health records. *NPJ Digital Medicine*, 1(1), 18.

Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., & Yang, G. Z. (2017). Deep learning for health informatics. *IEEE Journal of Biomedical and Health Informatic*, 21(1), 4–21.

Saltz, J., Sharma, A., Iyer, G., Bremer, E., Wang, F., Jasniewski, A., . . . Kurc, T. (2017). A containerized software system for generation, management, and exploration of features from whole slide tissue images. *Cancer Research*, 77(21), e79–e82.

Savova, G. K., Masanz, J. J., Ogren, P. V., Zheng, J., Sohn, S., Kipper-Schuler, K. C., & Chute, C. G. (2010). Mayo clinical Text Analysis and Knowledge Extraction System (cTAKES): Architecture, component evaluation and applications. *Journal of the American Medical Informatics Association: JAMIA*, 17(5), 507–513.

Sendak, M. P., D'Arcy, J., Kashyab, S., Gao, M., Nichols, M., Corey, K., . . . Balu, S. (2020). A path for translation of machine learning products into healthcare delivery. *EMJ Innov*. Retrieved on August 20, 2020, from <https://www.emjreviews.com/innovations/article/a-path-for-translation-of-machine-learning-products-into-healthcare-delivery/>

Seymour, C. W., Liu, V. X., Iwashyna, T. J., Brunkhorst, F. M., Rea, T. D., Scherag, A., . . . Angus, D. C. (2016). Assessment of clinical criteria for sepsis: For the third international consensus definitions for sepsis and septic shock (sepsis-3). *JAMA*, 315(8), 762–774.

Shashikumar, S. P., Josef, C., Sharma, A., & Nemati, S. (2019). *DeepAISE—an end-to-end development and deployment of a recurrent neural survival model for early prediction of sepsis*. ArXiv Prepr ArXiv190804759.

Shortliffe E.H., & Fagan L.M. (1985). Artificial Intelligence: the expert systems approach to medical consultation. In P. M. Osswald (Eds.). *Computers in critical care and pulmonary medicine*. Berlin: Springer.

Sirin Software. (2018). *Kubernetes - a new advanced container management power*. Retrieved on August 20, 2020, from <https://sirinsoftware.com/blog/kubernetes-a-new-advanced-container-management-power/>

- Soysal, E., Wang, J., Jiang, M., Wu, Y., Pakhomov, S., Liu, H., . . . Xu, H. (2018). CLAMP - a toolkit for efficiently building customized clinical natural language processing pipelines. *Journal of the American Medical Informatics Association: JAMIA*, 25(3), 331–336.
- Tangri, N., Stevens, L. A., Griffith, J., Tighiouart, H., Djurdjev, O., Naimark, D., . . . Levey, A. (2011). A predictive model for progression of chronic kidney disease to kidney failure. *JAMA*, 305(15), 1553–1559.
- Topol, E. J. (2019). High-performance medicine: The convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44–56.
- Ugalmugle, S., & Devgire, A. (2019). Global digital healthcare market size to exceed \$504.4 Bn by 2025. *Global Market Insights, Inc.* Retrieved on August 20, 2020, from <https://www.gminsights.com/pressrelease/digital-health-market>
- Voigt, P., & von dem Bussche, A. (2017). Scope of application of the GDPR. In P. Voigt, & A. von dem Bussche (Eds.). *The EU General Data Protection Regulation (GDPR): A practical guide* (pp. 9–30). Cham, Switzerland: Springer International Publishing. Retrieved on August 20, 2020, from: https://doi.org/10.1007/978-3-319-57959-7_2
- Wang, S., Jiang, X., Wu, Y., Cui, L., Cheng, S., & Ohno-Machado, L. (2013). EXpectation Propagation LOGistic REGression (EXPLORER): Distributed privacy-preserving online model learning. *Journal of Biomedical Informatics*, 46(3), 480–496.
- Wu, Y., Jiang, X., Kim, J., & Ohno-Machado, L. (2012). Grid Binary LOGistic REGression (GLORE): Building shared models without sharing data. *Journal of the American Medical Informatics Association: JAMIA* 19(5), 758–64.
- Yu, H., Sun, H., Wu, D., & Kuo T-T. (2020). Comparison of smart contract blockchains for healthcare applications. *Proceedings of the Annual AMIA Symposium*, 1266–1275.
- Zech, J. R., Badgeley, M. A., Liu, M., Costa, A. B., Titano, J. J., & Oermann, E. K. (2018). Variable generalization performance of a deep learning model to detect pneumonia in chest radiographs: A cross-sectional study. *PLoS Medicine*, 15(11), e1002683. Retrieved on August 20, 2020, from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6219764>

Machine learning in cardiovascular medicine

Marco Antonio Gutierrez¹ and José Eduardo Krieger²

Nature and complexity of health data

The increase in the use of Electronic Health Records (EHR) in hospitals and clinics around the world has led to the creation of patient data sets that are very voluminous, heterogeneous, and continually expanding and incorporating new variables.

Data related to health care is complex and offers numerous computational challenges. This complexity is partially inherent to health conditions, on top of the heterogeneity of these conditions. In this context, cardiovascular diseases are considered a paradigm, since they represent a major burden for health systems due to their prevalence and to more basic factors that involve a complex interaction between genetic and environmental factors. In addition, some of these factors can interact with regulatory systems that maintain a harmful influence even decades later, when the signs and symptoms of the diseases are manifested. The complexity is also result of the irregular nature of patient information collection and the type of variables collected at a given point in time. These variables may reflect an acute event related to health and not a structured set of variables for an individual's long-term health management. Furthermore, the interpretation of these measurements can vary over time (for example, acceptable cholesterol levels may change according to new scientific findings) and an acceptable interval (good, borderline, high, low) may vary depending on the method used (and, consequently,

¹ Post-doctorate in medical image processing from the University of Utrecht, in Holland (1996), PhD in electrical engineering from the Polytechnic School of the University of São Paulo - USP (1995), undergraduate degree from the School of Engineering of USP in São Carlos (1985). Medical Informatics professor at the Federal University of São Paulo - UNIFESP (2008) and part of the Department of Cardiopulmonology of the USP Medical School, where he is an assistant professor. Head of the Informatics Service and Biomedical Informatics Laboratory of the Heart Institute (HC-FMUSP).

² Post-doctorate in molecular biology from Harvard Medical School (1990) and Stanford University School of Medicine in the United States (1992), PhD in physiology from the Wisconsin School of Medicine, also in the United States (1988), undergraduate degree from the Ribeirão Preto Medical School, USP (1984). Member of the Department of Cardiopulmonology of the USP Medical School, where he is a full professor of Molecular Medicine and head of the Genetics and Molecular Cardiology Laboratory of the Heart Institute (HC-FMUSP).

through the improvement of techniques). Finally, there is an abundance of collected and stored data related to visits, including diagnoses, prescriptions, lab tests, imaging procedures, medications and interventions. The types of biomedical data include free text, structured data and multi-dimensional signs: electrocardiograms (ECGs), 2D imaging (X-rays), 3D volumes (such as computed tomography or magnetic resonance) and 4D data (such as acquisition of temporal 3D cardiac magnetic resonance imaging + time).

The omics revolution

The decoding of the human genome in 2003 added a new dimension for approaching the study of diseases. It was followed by the creation of human genetic variant databases, such as the International HapMap Project (Altshuler & Donnelly, 2005) and the 1000 Genomes Project (The 1000 Genomes Project Consortium, 2012) which, together with the evolution of genotyping technologies, enabled the first genome-wide association study (GWAS) of complex diseases. In subsequent studies, using a larger number of individuals and meta-analysis, where data from different resources are integrated using genotype imputation (Howie, Donnelly, & Marchini, 2009) based on genetic variant databases, thousands of these variants associated with one or more complex traits were identified (Visscher et al., 2017). However, most of the variants identified thus far provide a small risk effect and explain only a small fraction of phenotypic variance or family grouping and fail to answer the primary question related to complex inherited diseases (Teixeira, Pereira, & Krieger, 2018; Giri et al., 2019; Evangelou et al., 2017).

In 2004, the first big consortium was launched to identify epigenetic marks in different tissues and cell types, called ENCODE (ENCODE Project Consortium, 2004). More than 10 years later, the Roadmap Epigenomics Mapping Consortium had generated the largest collection to date of human epigenomes for primary cells and tissues (Kundaje et al., 2015). A variety of trials was used, including chromatin immunoprecipitation (ChIP), DNA digestion by DNaseI (DNase), bisulfite treatment, methylated DNA immunoprecipitation (MeDIP), digestion by methylation-sensitive restriction enzymes (MSREs), and RNA profiles, each followed by short-term, massively parallel sequencing. The data was processed and made available in a public repository for use by the scientific community. In 2017, a new endeavor to improve the Genotype-Tissue Expression (GTEx) Project, referred to as the Enhancing GTEx (eGTEx) Project, was introduced. Its goal is to “combine gene expression with additional intermediate molecular measurements on the same tissues to provide a resource for studying how genetic differences cascade through molecular phenotypes to impact human health” (Stranger et al., 2017). All these public databases permit multiple layer analysis to understand the molecular complexity of common diseases.

Artificial Intelligence in health data integration

One solution to overcoming difficulties with extracting significant information that could be hidden in voluminous and complex sets of health data is the use of Artificial Intelligence or machine learning techniques.

Machine learning research has come in waves. The first, in the 1960s, introduced the proposal of artificial neurons and the first artificial neural network (ANN) architectures, Perceptron and Adaline. These networks were limited to solving problems that involved linearly separable classes, and the training algorithms were only applied to single-layer networks. The second wave, in the 1980s, was based on the introduction of the backpropagation method for training networks with hidden layers, and resulted in significant improvements in solving problems related to recognizing patterns in certain areas of knowledge. However, applications in the area of health sciences were still very limited. At the end of the 20th Century, the proposal of RNA for solving complex problems, such as the analysis of images, required a more complete set of new architectures, as well as greater computational power to enable training of networks with a larger number of layers, or deep layers. Deep neural networks, also known as deep learning, which emerged at the end of the first decade of the 21st century, represent the third wave. Among these networks, convolutional neural networks (CNN) have the most applications. They introduced a fundamental change in RNA architecture, which was the importance of convolution layers. Instead of multiplying enormous weight matrices by activating previous layers, CNN uses the convolution of small filters with a small number of these activations. This change significantly reduces the memory used for storing the parameters of networks. In addition, a new layer – a sample layer – was introduced, inspired by the processing of the mammalian visual cortex. It provides networks with invariance for small translations, rotations and, occasionally, additive noise in an image. Finally, a fundamental change with the third wave was that, unlike the previous generation of learning tools, CNN does not need a previous feature extraction stage. The initial layers of the architecture are now responsible for this task. From a computational point of view, graphic processing units (GPU) imparted the necessary computational power for the current technological evolution. CNN was considered one of the greatest technological advances of 2013 (Hof, 2013).

Over the course of these three waves, there has been a significant increase in the depth of networks, or the number of the layers and, consequently, in the numbers of neurons of these networks. Furthermore, for supervised training of increasingly deeper architectures, it is necessary to have labeled and annotated databases with thousands of examples.

Until now, one of the main focuses of these studies has been the detection and segmentation of structures of interest in medical images (Cireşan, Giusti, Gambardella, & Schmidhuber, 2013; Oliveira et al., 2018; Tajbakhsh, Gurudu, & Liang, 2015; Tajbakhsh, Gotway, & Liang, 2015). However, there is a growing interest in natural language processing in health through deep learning, since a large amount of medical knowledge is contained in free texts, which are recorded in the narratives of EHR, such as those existing in anamnesis, evolution, and clinical summaries, among others.

The increasing use of EHR provides a unique opportunity for analysis of secondary data in health and, through these databases, identifying phenotypes of patients that could indicate specific diseases or risks of developing diseases. In the very near future, the adoption of machine learning in the field of health, especially for automatic determination of phenotypes of patients, could be an important tool for supporting clinical practices, by reducing the analysis and assessment time for a patient's history and enhancing the accuracy of the diagnosis (Gehrmann et al., 2018).

Medical imaging analysis

The assessment of diseases through medical imaging strongly depends on the interpretation of images by human specialists (radiologists). This has changed rapidly in the last few decades, as computational methods have improved the image interpretation process, providing powerful tools to help physicians obtain more accurate diagnoses (Greenspan, Ginneken, & Summers, 2016; Litjens et al., 2017; Shen, Wu, & Suk, 2017).

An image-based diagnostic process generally requires a preliminary search for target structures (segmentation), quantification of parameters and metrics (such as form, size, movement and opacity) to find possible abnormalities, or searching for changes in parameters over the course of time, among others. The field of computerized medical imaging analysis has been addressing these problems since the 1970s. Processing techniques, initially used at the pixel level, rapidly evolved into mathematical modeling by rule-based systems (Greenspan et al., 2016). Although these techniques may have worked very well for specific tasks, they are not generalizable for a wide range of applications. The introduction of machine learning techniques has changed this scenario, becoming a powerful tool to facilitate the identification of abnormalities and assist in the workflow of physicians (Shen et al., 2017).

The transition from model-based systems to systems that learn through data was gradual in the beginning. However, the number of articles published in the area has been increasing considerably since 2015. Among these techniques, deep learning has been emerging as the state-of-the-art, leading to greater accuracy and opening up new frontiers in medical imaging analysis (Greenspan et al., 2016). Deep learning methods have been used for segmentation, detection of objects or wounds, classification, registration, and tracking, among other applications. Deep learning is currently applied more to medical imaging than to any other type of health data (Wainberg, Merico, Delong, & Frey, 2018).

Despite the advances in the area, there are many challenges to be faced. The lack of large training data sets is frequently considered a major obstacle, since small training data sets can lead to inaccurate decisions (Krittanawong, Zhang, Wang, Aydar, & Kitai, 2017).

Physiological signal analysis

Physiological signals are invaluable data sources that assist in the detection, rehabilitation and treatment of diseases (Faust & Bairy, 2012). The signals come from sensors implanted under or placed in contact with the skin (Wang & Shang, 2013). The location of these sensors determines the features of the physiological signals, whose relevant information needs to be extracted to support a specific health application (Devasahayam, 2013).

Recently, deep learning architectures have been proposed for automatic signal analysis, taking into consideration all the information that a training data set has to offer. As in other health applications, the main goal of using deep learning methods is to create a good representation of features and knowledge from the input data (Rahhal et al., 2016). Applications described for physiological signals include: classification of sleep stages from polysomnography data (Långkvist, Karlsson, & Loutfi, 2012); prediction of epileptic seizures from electroencephalogram (EEG) signals (Mirowski, LeCun, Madhavan, & Kuzniecky, 2008); automatic classification of ECG signals (Mathews, Kambhamettu, & Barner, 2018; Rahhal et al., 2016); and detection of cardiac arrhythmias (Isin & Ozdalili, 2017).

Analysis of narratives

Natural language processing (NLP) techniques have been used to identify, extract and process unstructured data from EHR and, consequently, harness the great potential of clinical information in electronic records (Agarwal et al., 2016; Murff et al., 2011; Huang et al., 2014; Jung et al., 2015; Liao et al., 2015; Carrell et al., 2014). These NLP tools can also substantially reduce the time spent by clinicians in reviewing medical records (Rahman et al., 2011), and thereby optimize their time for seeing patients or investing in other research activities (Chen et al., 2016; Topaz et al., 2016). The main stages involved in NLP are: segmentation, division into sentences or words (tokenization), normalization, syntactic analysis, semantic analysis, and classification (Pons, Braun, Hunink, & Kors, 2016).

After obtaining the free texts from medical records, processing starts with segmentation and the selection of sections of interest (for example, the focus of a study might be only the section “diagnostic hypothesis” of a radiology report). After this definition, the text is divided into sentences and/or words – a process known as tokenization – which are then normalized or sanitized. Two processes stand out: stemming, which is the process of reducing a word to its word stem (“car”, “cars”, “cars”, “cars” are mapped to the word “car”); and lemmatization, which represents the words through the infinitive of verbs (“am”, “is” “is” are mapped as “be”) and masculine singular for nouns and names.

In the process of extracting variables, the subsequent syntactic analysis classifies words (name, verb, adjective), grammatical structures (verb phrase, noun phrase), and relations of dependence (subject or object). The semantic analysis assigns meaning to words and phrases (for example, symptoms, diseases, procedures) and concepts. In this stage, dictionaries for vocabularies and synonyms may be used, such as the Metathesaurus of RadLex (Langlotz, 2006) and the Unified Medical Language System

(UMLS) (Bodenreider, 2004). Both of these dictionaries specialize in radiology and are available in English.

After extracting the variables of interest in the free text, the last stage in NLP involves classification (for example, whether a patient's report contains a diagnosis of a disease). This procedure is also known as patient phenotyping. Rule-based methods, machine learning, or hybrid methods can be used for this processing. The results of the first approach are generally satisfactory when the domain is very well-defined (Chapman, Lee, Kang, & Chapman, 2011; Kirby et al., 2016). The problem is that this process requires experts with a deep understanding of each condition, in addition to major efforts in the creation of algorithms.

Recent developments in the use of machine learning in the health field have permitted patient phenotyping without the need for strong knowledge of the area (Chen et al., 2017; Esteva et al., 2017; Gehrmann et al., 2018; Gulshan et al., 2016; LeCun, Bengio, & Hinton, 2015).

Omic data integration

The development of genetic experiments has resulted in large databases that require dedicated bioinformatics pipelines, algorithms, and high-performance computing machines to deal with issues related to risk prediction and the development of more effective and personalized disease management. Many different mathematical and computational analyses are being done to identify causal variants and select genes whose expression is directly affected by them, thus obtaining a better understanding of the molecular mechanisms underlying the development of common diseases, such as colocalization analysis, mendelian randomization, and transcriptome-wide association studies (TWAS) (Heinig, 2018). In fact, some of these analyses use imputation to overcome the difficulty of having different types of data from the same samples, in order to predict the results of different experiments and integrate them, for example.

Despite having identified millions of common genetic variants associated with a disease or disease phenotype, these variants, individually or in combination, only explain a fraction of the phenotypic variance. This is the case for various cardiovascular diseases and has led to the search for low-frequency and rare variants that may influence observed family traits and groupings (Manolio et al., 2009). However, this approach has only gained ground in recent years, due to lower costs of the entire genome and sequencing of exomes, and the development of large consortia, whose main objective was the sequencing of the human population.

In addition, to be effective and important at the clinical level, it is necessary to understand the role of common and low-frequency genetic variants within the genetic architecture of the traits of diseases. In 2012, Maurano et al. demonstrated that most of the common genome-wide associations studies (GWAS) are found in non-coding regions and are over-represented in DNA regulatory sites. Furthermore, these variants disrupt the recognition of transcription factor sites that alter allelic chromatin states and appear to be enriched in tissues related to characteristics. Subsequent studies have confirmed these findings for different diseases and characteristics (Smemo et

al., 2014; Soldner et al., 2016). The information generated by different genomic data was used to develop algorithms to predict disease risk. At first, the scientific community focused on simple strategies based on classical statistics (for example, linear regressions and multiple logistics) (Cox et al., 2014; Fava et al., 2013; Justesen et al., 2015). At present, different machine learning techniques should be used, such as deep learning, to identify genetic patterns, as well as develop adequate disease risk predictors using genomic information (Li et al., 2018).

Therefore, the integration of different omics data is essential for understanding the influence of these genetic variants on the development of the feature, which will enable them to be used in predictive risk algorithms and to adapt patient disease management.

Final comments

The challenges for the coming years are promising. That is because this is a time when many challenges can be tackled more efficiently with new technologies. Yet, at the same time, enormous sums are being spent on health systems under various dysfunctional and poorly integrated aspects, all of which creates a “perfect storm.” On the one hand, there are cases, such as the U.S. system, where health spending represents approximately 20% of the gross domestic product (GDP), which is the largest economy on the planet and the country does not have the best population health indicators. On the other hand, there is the case of Brazil, which has low per capita spending and a well-designed and structured public health system but, in reality, due to underfinancing, the system is dysfunctional and needs to be improved. These two realities are in need of reform, and new technologies based on Artificial Intelligence, due to their cross-sectional operational characteristics and being in various stages of this process, will play an important role in streamlining health systems, in terms of advances in and implementation of personalized medicine for health promotion, development of individual prevention strategies, and providing support for decisions to more rationally minimize the effects of diseases.

References

- Agarwal, V., Podchiyska, T., Banda, J. M., Goel, V., Leung, T. I., Minty, E. P., . . . Shah, N. H. (2016). Learning statistical models of phenotypes using noisy labeled training data. *Journal of the American Medical Informatics Association : JAMIA*, 23(6), 1166–1173.
- Altshuler, D., & Donnelly, P. (2005). A haplotype map of the human genome. *Nature*, 437(7063), 1299–1320.
- Bodenreider, O. (2004). The Unified Medical Language System (UMLS): integrating biomedical terminology. *Nucleic Acids Research*, 32, D267–D270.
- Carrell, D. S., Halgrim, S., Tran, D. T., Buist, S. M., Chubak, J., Chapman, W., & Savova, G. (2014). Using natural language processing to improve efficiency of manual chart abstraction in research: The case of breast cancer recurrence. *American Journal of Epidemiology*, 179(6), 749–758.
- Chapman, B. E., Lee, S., Kang, H. P., & Chapman, W. W. (2011). Document-level classification of CT pulmonary angiography reports based on an extension of the ConText algorithm. *Journal of Biomedical Informatics*, 44(5), 728–737.
- Chen, L., Guo, U., Illipparambil, L. C., Netherton, M. D., Sheshadri, B., Karu, E., . . . Mehta, P. H. (2016). Racing against the clock: Internal medicine residents' time spent on electronic health records. *Journal of Graduate Medical Education*, 8(1), 39–44.
- Chen, M. C., Ball, R. L., Yang, L., Moradzadeh, N., Chapman, B. E., Larson, D. B., . . . Lungren, M. P. (2017). Deep learning to classify radiology free-text reports. *Radiology*, 286(3), 845–852.
- Cireşan, D. C., Giusti, A., Gambardella, L. M., & Schmidhuber, J. (2013). Mitosis detection in breast cancer histology images with deep neural networks. In K. Mori, I. Sakuma, Y. Sato, C. Barillot, & N. Navab (Eds.), *Medical image computing and computer-assisted intervention – MICCAI 2013* (pp. 411–418). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Cox, A. J., Hsu, F. C., Ng, M. C. Y., Langefeld, C. D., Freedman, B. I., Carr, J. J., & Bowden, D. W. (2014). Genetic risk score associations with cardiovascular disease and mortality in the diabetes heart study. *Diabetes Care*, 37(4), 1157–1164.
- Devasahayam, S. R. (2013). *Signals and systems in biomedical engineering: Singal processing and physiological systems modeling*. Springer.
- ENCODE Project Consortium. (2004). The ENCODE (ENCyclopedia of DNA elements) Project. *Science*, 306(5696), 636–640.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542, 115.
- Evangelou, E., Warren, H. R., Mosen-Ansorena, D., Mifsud, B., Pazoki, R., Gao, H., . . . the Million Veteran Program (2017). Genetic analysis of over one million people identifies 535 novel loci for blood pressure. *BioRxiv*, 50(October), 198234.
- Faust, O., & Bairy, M. G. (2012). Nonlinear analysis of physiological signals: a review. *Journal of Mechanics in Medicine and Biology*, 12(4), 1240015.

- Fava, C., Sjögren M., Montagnana M., Danese, E., Almgren, P., Engström G., . . . Melander, O. (2013). Prediction of blood pressure changes over time and incidence of hypertension by a genetic risk score in Swedes. *Hypertension*, 61(2), 319–326.
- Gehrmann, S., Dernoncourt, F., Li, Y., Carlson, E. T., Wu, J. T., Welt, J., . . . Celi, L. A. (2018). Comparing deep learning and concept extraction based methods for patient phenotyping from clinical narratives. *PLOS ONE*, 13(2), e0192360.
- Giri, A., Hellwege, J. N., Keaton, J. M., Park, J., Qiu, C., Warren, H. R., . . . Hung, A. M. (2019). Trans-ethnic association study of blood pressure determinants in over 750,000 individuals. *Nature Genetics*, 51(1), 51–62.
- Greenspan, H., Ginneken, B. van, & Summers, R. M. (2016). Guest editorial deep learning in medical imaging: Overview and future promise of an exciting new technique. *IEEE Transactions on Medical Imaging*, 35(5), 1153–1159.
- Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., . . . Webster, D., R. (2016). Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA*, 316(22), 2402–2410.
- Heinig, M. (2018). Using gene expression to annotate cardiovascular GWAS Loci. *Frontiers in Cardiovascular Medicine*, 5, 59.
- Hof, R. D. (2013). 10 breakthrough technologies 2013: Deep learning. *MIT Technology Review*. Retrieved on May 17, 2020, from <https://www.technologyreview.com/10-breakthrough-technologies/2013/>
- Howie, B. N., Donnelly, P., & Marchini, J. (2009). A flexible and accurate genotype imputation method for the next generation of genome-wide association studies. *PLoS Genetics*, 5(6), e1000529–e1000529.
- Huang, S. H., LePendur, P., Iyer, S. V., Tai-Seale, M., Carrell, D., & Shah, N. H. (2014). Toward personalizing treatment for depression: Predicting diagnosis and severity. *Journal of the American Medical Informatics Association : JAMIA*, 21(6), 1069–1075.
- Isin, A., & Ozdalili, S. (2017). Cardiac arrhythmia detection using deep learning. *Procedia Computer Science*, 120, 268–275.
- Jung, K., LePendur, P., Iyer, S., Bauer-Mehren, A., Percha, B., & Shah, N. H. (2015). Functional evaluation of out-of-the-box text-mining tools for data-mining tasks. *Journal of the American Medical Informatics Association: JAMIA*, 22(1), 121–131.
- Justesen, J. M., Allin, K. H., Sandholt, C. H., Borglykke, A., Krarup, N. T., Grarup, N., . . . Pedersen, O. (2015). Interactions of lipid genetic risk scores with estimates of metabolic health in a Danish population. *Circulation: Cardiovascular Genetics*, 8(3), 465–472.
- Kirby, J. C., Speltz, P., Rasmussen, L. V., Basford, M., Gottesman, O., Peissig, P. L., . . . Denny, J. C. (2016). PheKB: A catalog and workflow for creating electronic phenotype algorithms for transportability. *Journal of the American Medical Informatics Association : JAMIA*, 23(6), 1046–1052.
- Krittanawong, C., Zhang, H., Wang, Z., Aydar, M., & Kitai, T. (2017). Artificial intelligence in precision cardiovascular medicine. *Journal of the American College of Cardiology*, 69(21), 2657–2664.

- Kundaje, A., Meuleman, W., Ernst, J., Bilenky, M., Yen, A., Heravi-Moussavi, A., . . . Kellis, M. (2015). Integrative analysis of 111 reference human epigenomes. *Nature*, 518(7539), 317–330.
- Långkvist, M., Karlsson, L., & Loutfi, A. (2012). Sleep stage classification using unsupervised feature learning. *Advances in Artificial Neural Systems*, 2012, 1–9.
- Langlotz, C. P. (2006). RadLex: A New method for indexing online educational materials. *RadioGraphics*, 26(6), 1595–1597.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521, 436.
- Li, J., Pan, C., Zhang, S., Spin, J. M., Deng, A., Leung, L. L. K., . . . Snyder, M. (2018). Decoding the genomics of abdominal aortic aneurysm. *Cell*, 174(6), 1361–1372.e10.
- Liao, K. P., Cai, T., Savova, G. K., Murphy, S. N., Karlson, E. W., Ananthakrishnan, A. N., . . . Kohane, I. (2015). Development of phenotype algorithms using electronic medical records and incorporating natural language processing. *BMJ : British Medical Journal*, 350.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., . . . Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88.
- Manolio, T. A., Collins, F. S., Cox, N. J., Goldstein, D. B., Hindorff, L. A., Hunter, D. J., . . . Visscher, P. M. (2009). Finding the missing heritability of complex diseases. *Nature*, 461(7265), 747–753.
- Mathews, S. M., Kambhamettu, C., & Barner, K. E. (2018). A novel application of deep learning for single-lead ECG classification. *Computers in Biology and Medicine*, 99, 53–62.
- Maurano, M. T., Humbert, R., Rynes, E., Thurman, R. E., Haugen, E., Wang, H., . . . Stamatoyannopoulos, J. A. (2012). Systematic localization of common disease-associated variation in regulatory DNA. *Science (New York, N.Y.)*, 337(6099), 1190–1195.
- Mirowski, P. W., LeCun, Y., Madhavan, D., & Kuzniecky, R. (2008). Comparing SVM and convolutional networks for epileptic seizure prediction from intracranial EEG. *2008 IEEE Workshop on Machine Learning for Signal Processing*, 244–249.
- Murff, H. J., FitzHenry, F., Matheny, M. E., Gentry, N., Kotter, K. L., Crimin, K., . . . Speroff, T. (2011). Automated identification of postoperative complications within an electronic medical record using natural language processing. *JAMA*, 306(8), 848–855.
- Oliveira, D. A. B., Macedo, M. M. G., Nicz, P., Campos, C., Lemos, P., & Gutierrez, M. A. (2018). Coronary calcification identification in optical coherence tomography using convolutional neural networks. *Proc. SPIE, Medical Imaging 2018: Biomedical Applications in Molecular, Structural, and Functional Imaging*, 10578, 105781Y–10578–7.
- Pons, E., Braun, L. M. M., Hunink, M. G. M., & Kors, J. A. (2016). Natural Language Processing in Radiology: A Systematic Review. *Radiology*, 279(2), 329–343.
- Rahhal, M. M. Al, Bazi, Y., AlHichri, H., Alajlan, N., Melgani, F., & Yager, R. R. (2016). Deep learning approach for active classification of electrocardiogram signals. *Information Sciences*, 345, 340–354.
- Rahman, S., Majumder, M. A. A., Shaban, S. F., Rahman, N., Ahmed, M., Abdulrahman, K. B., & D'Souza, U. J. (2011). Physician participation in clinical research and trials: Issues and approaches. *Advances in Medical Education and Practice*, 2, 85–93.

- Shen, D., Wu, G., & Suk, H.-I. (2017). Deep learning in medical image analysis. *Annual Review of Biomedical Engineering*, 19(1), 221–248.
- Smemo, S., Tena, J. J., Kim, K. H., Gamazon, E. R., Sakabe, N. J., Gómez-Marín, C., . . . Nóbrega, M. A. (2014). Obesity-associated variants within FTO form long-range functional connections with IRX3. *Nature*, 507(7492), 371–375.
- Soldner, F., Stelzer, Y., Shivalila, C. S., Abraham, B. J., Latourelle, J. C., Barrasa, M. I., . . . Jaenisch, R. (2016). Parkinson-associated risk variant in distal enhancer of α -synuclein modulates target gene expression. *Nature*, 533(7601), 95–99.
- Stranger, B., Brigham, L., Hasz, R., Hunter, M., Johns, C., Johnson M., . . . Montgomery S. B. (2017). Enhancing GTEx by bridging the gaps between genotype, gene expression, and disease. *Nature Genetics*, 49, 1664–1670.
- Tajbakhsh, N., Gotway, M. B., & Liang, J. (2015). Computer-aided pulmonary embolism detection using a novel vessel-aligned multi-planar image representation and convolutional neural networks. In *Lecture Notes in Computer Science* (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics) (Vol. 9350, pp. 62–69).
- Tajbakhsh, N., Gurudu, S. R., & Liang, J. (2015). Automatic polyp detection in colonoscopy videos using an ensemble of convolutional neural networks. *2015 IEEE 12th International Symposium on Biomedical Imaging (ISBI)*, 79–83.
- Teixeira, S. K., Pereira, A. C., & Krieger, J. E. (2018). Genetics of resistant hypertension: The missing heritability and opportunities. *Current Hypertension Reports*, 20(6), 48.
- The 1000 Genomes Project Consortium. (2012). An integrated map of genetic variation from 1,092 human genomes. *Nature*, 491(7422), 56–65.
- Topaz, M., Lai, K., Dowding, D., Lei, V. J., Zisberg, A., Bowles, K. H., & Zhou, L. (2016). Automated identification of wound information in clinical notes of patients with heart diseases: Developing and validating a natural language processing application. *International Journal of Nursing Studies*, 64, 25–31.
- Visscher, P. M., Wray, N. R., Zhang, Q., Sklar, P., McCarthy, M. I., Brown, M. A., & Yang, J. (2017). 10 years of GWAS discovery: Biology, function, and translation. *American Journal of Human Genetics*, 101(1), 5–22.
- Wainberg, M., Merico, D., Delong, A., & Frey, B. J. (2018). Deep learning in biomedicine. *Nature Biotechnology*, 36, 829.
- Wang, D., & Shang, Y. (2013). Modeling physiological data with deep belief networks. *International Journal of Information and Education Technology (IJJET)*, 3(5), 505–511.

COVID-19: Information and decisions for adopting lockdown¹

Eduardo Massad²

Introduction

On February 26, 2020, a 61-year-old man from São Paulo who had returned from a trip to Italy tested positive for SARS-CoV-2, the virus that causes COVID-19. Although there is some controversy on the matter, he can be considered patient zero of the disease in Brazil. From that time up to May 11, 2020, 162,699 cases were confirmed, most in the state of São Paulo. This resulted in 11,123 deaths and led to the collapse of healthcare systems in some cities.

Brazil is among the countries with the highest transmission rates of SARS-CoV-2, with a reproducibility rate at the onset of the epidemic of 3.5. This means that in the beginning, each infected person was capable of infecting another 3.5 susceptible individuals. After some effort to implement social distancing measures, the country was able to reduce this initial rate by 50%. With these measures, each patient was then capable of infecting another 1.7 susceptible individuals. Experts estimated that if this rate of growth continued, the number of cases would reach catastrophic dimensions by the end of the pandemic, with a total of 34 million infected persons.

This article presents mathematical and computational techniques that enable projections of the main values of epidemiological interest, with the goal of helping public health authorities plan better strategies to mitigate the epidemic.

¹ At the time this article was delivered for publication, on May 17, 2020, there were 241,080 confirmed cases of people infected with the new coronavirus in Brazil and 16,118 deaths, according to official data from the Ministry of Health. At the conclusion of this edition of the ICT in Health 2019 survey, on August 29, 2020, Brazil had 3,846,153 cases and 120,462 deaths, making it the country with the second highest cumulative number of deaths after the United States, according to the special epidemiological bulletin of the Ministry of Health. Retrieved on September 2, 2020, from <https://coronavirus.saude.gov.br/boletins-epidemiologicos>

² Full professor at the School of Applied Mathematics of the Getulio Vargas Foundation (EMAp/FGV). Physician and physicist, PhD in experimental pathology from the University of São Paulo (USP). Retired professor of medical informatics at USP and head of the Department of Legal Medicine of USP. Honorary professor of infectious diseases at the London School of Hygiene and Tropical Medicine, visiting professor of medicine at the National University of Singapore, and statistics and psychology professor at the University of Derby.

How to make predictions with very little information

Since the first mathematical models that described the smallpox dynamics were proposed by Daniel Bernoulli in the 18th century, there has been rapid progress in the application of these tools to the planning of public health strategies (Bernoulli, 1995). Since the 1970s, there has been great progress in this area and, currently, mathematical, and computational models are already included in the tools used by epidemiologists worldwide.

Deterministic and/or stochastic behavioral models have had the widest dissemination as a means of understanding the dynamics of epidemics. These methods involve dividing the total population into “compartments” that correspond to the various stages of the natural evolution of the infection. In the simplest model, the total population is assigned to categories labeled “susceptible” or “infectious” (SI). Starting in the mid-1920s, however, with the work of Kermack and Mackendrick (1927), a third compartment was introduced, corresponding to patients who were “removed” from the chain of transmission, either because they were deceased or because they recovered from the infection. These are called SIR models. This basic structure has become more sophisticated, depending on the complexity of the infection cycle analyzed.

Because SARS-CoV-2 infection has a lengthy incubation period, the most adequate model to describe the infection dynamic is SEIR, in which E corresponds to individuals “exposed” to the infectious agent. This is the model that has been used to explain the COVID-19 pandemic.

Based on this compartmental structure, systems of equations are introduced to describe the “flow” between the different compartments, reproducing the dynamics of the natural history of the epidemic's evolution. The models begin to be simulated in a computer environment with parameters that determine their dynamics, obtained from mathematical deductions and empirical data from the epidemic. Based on the results of the simulations, projections are made about the behavior of each variable at future points in time, and intervention strategies are simulated to establish the best way to control the epidemic.

One of the factors that determine the intensity of transmission of an infectious agent is the basic reproduction number, called R_0 , which is defined as the number of secondary cases produced by a single (typical) infection in a completely susceptible population during its infectious period. R_0 is calculated as the rate of infection divided by the sum of the rates of removal. Figure 1 illustrates these dynamics.

FIGURE 1

DYNAMICS OF THE BASIC REPRODUCTION NUMBER OF THE INFECTION



SOURCE: PREPARED BY THE AUTHOR.

Since the number of susceptible individuals falls by 100% over time, another parameter is defined, called the effective reproduction number, or $R(t)$, and that is defined as the number of people who become infected by an infectious person at each point in time. The effective reproduction number is the product of R_0 multiplied by the fraction of susceptible individuals at each point in time. If all susceptible individuals are denominated $S_H(t)$ at each point in time, and the total population is represented by $N_H(t)$, the $R(t)$ is calculated as follows:

$$R(t) = R_0 \frac{S_H(t)}{N_H(t)}$$


Note that when $t = 0$, $S_H(t) = N_H(t)$, and $R(t) = R_0$. This is the “ R_t ” parameter that has been disseminated by the media.

A model for COVID-19

The SEIR model can be used to study the dynamics of COVID-19 among the susceptible population. One possible model structure is illustrated in Figure 2.

FIGURE 2

SEIR MODEL STRUCTURE FOR THE COVID-19 DYNAMICS



SOURCE: PREPARED BY THE AUTHOR.

In this model, $S_H(t)$ represents the population of susceptible individuals, $E_H(t)$ the population of those exposed to the virus, $I_H(t)$ those infected by the virus, $G_H(t)$ severe cases of the disease that require hospital care, and finally, $R_H(t)$ which represents the population of individuals who have recovered from the disease.

The parameters of the model are: Λ_H , which represents the population growth rate, whether by birth or migration; μ_H , which represents the death rate from all other causes besides the virus; β , the rate of contact with potentially infectious individuals; δ_H , the inverse of the period of incubation; α_H , the mortality rate due to the disease; π_H , the progression rate for severe cases of the disease; σ_H , the additional mortality rate of severely ill patients; γ_H , the recovery rate of those infected; and θ_H , the recovery rate of severely ill patients. Parameters p and q were introduced to weight the contribution of variables $E_H(t)$ and $I_H(t)$ to the infection of susceptible individuals. Finally, parameter k was introduced to simulate social distancing measures. This parameter varies from 0 to 1.

The dynamics of this model is described by the following set of equations:

$$\begin{aligned}\frac{d}{dt} S_H(t) &= -\beta \kappa S_H \frac{(pE_H + qI_H)}{N_H} - \mu_S S_H + \Lambda_H \\ \frac{d}{dt} E_H(t) &= \beta \kappa S_H \frac{(pE_H + qI_H)}{N_H} - (\mu_S + \delta_H) E_H \\ \frac{d}{dt} I_H(t) &= \delta_H E_H - (\mu_S + \alpha_H + \gamma_H + \pi_H) I_H \\ \frac{d}{dt} G_H(t) &= \pi_H I_H - (\mu_S + \sigma_H + \theta_H) G_H \\ \frac{d}{dt} R_H(t) &= \gamma_H I_H + \theta_H G_H - \mu_S R_H\end{aligned}$$

This model's R_0 is given by the following equation:

$$R_0 = \frac{\delta_H \beta \kappa}{(\delta_H + \mu_H)(\gamma_H + \alpha_H + \mu_H + \pi_H)}$$

The value of R_0 can be calculated based on the rate of exponential growth at the onset of the epidemic, φ , given by the following equation:

$$R_0 = \varphi^2 + \frac{\varphi [(\delta_H + \mu_H) + (\gamma_H + \alpha_H + \mu_H + \pi_H)]}{(\delta_H + \mu_H)(\gamma_H + \alpha_H + \mu_H + \pi_H)} + 1$$

The incidence rate, defined as the number of new cases per unit of time, called $Inc(t)$, is given by:

$$Inc(t) = \beta \kappa S_H(t) \frac{I_H(t)}{N_H(t)}$$

The number of cases in an interval of time Δt is given by:

$$\bar{Cases}(t) = \int_{t_0}^{t_0+\Delta t} Inc(t) dt$$

The number of severe cases in an interval of time Δt is given by:

$$Severe(t) = \int_{t_0}^{t_0+\Delta t} \pi(t) I_H(t) dt$$

And the number of deaths is given by:

$$Deaths(t) = \int_{t_0}^{t_0+\Delta t} \left\{ \left[(\mu_H + \alpha_H) I_H(t) \right] + (\mu_H + \sigma_H) G_H(t) \right\} dt$$

The mortality rate of severely ill patients, σ_H , is considered to be a function of the number of patients, so it can increase as the hospital system is saturated.

The chosen function was:

$$\sigma_H(t) = \sigma_H(0) + [a_0 + a_1 t] [\theta(t_c - t_0)]$$


where $\theta(t_c - t_0)$ is the Heaviside step function, and t_c is the moment when the hospital system collapses.

How does this model behave with actual epidemiological data?

The charts below show the results of the model simulation for the number of infections and deaths up to May 11, 2020.

CHART 1

EVOLUTION IN NUMBER OF COVID-19 CASES BASED ON MODEL PROJECTIONS




SOURCE: PREPARED BY THE AUTHOR.

The red line in Chart 1 shows the initial exponential growth, which corresponded to a value of $R_0 = 3.5$, without, however, any mitigation measures. This curve represents the epidemic's “natural” growth. The blue dots represent actual COVID-19 cases, and the dotted line, the result of the model simulation using the parameter of a 50% reduction in β contact, representing social distancing of 50%. In this case, $R(t)$ falls proportionally by 50% to 1.75, i.e., in the current scenario, each case generates, on average, 1.75 other cases, a growth rate that is still very high.

Chart 2 shows the results of the model simulation using the parameters corresponding to the dotted curve of Chart 1 for deaths so far.

CHART 2

EVOLUTION IN NUMBER OF COVID-19 DEATHS BASED ON MODEL PROJECTIONS



SOURCE: PREPARED BY THE AUTHOR.

In Chart 2, the red dots represent actual accumulated mortality data up to mid-May, and the continuous line represents the result of the model simulation.


The charts show that the model recovers empirical epidemic data with good accuracy, which means that $R(t)$ at the time was 1.75, equivalent to an average of 50% of social distancing in the country and, furthermore, that the model is reliable enough to carry out projections.

What does "flattening the curve" mean?

Much has been said about "flattening the curve". This expression relates to the "epidemic curve", which is nothing more than the incidence curve, i.e., the number of new cases per unit of time. It is shaped like a bell, reaching a peak, the so called "epidemic peak", then falling to values very close to zero, or stabilizing at some endemic equilibrium (in this case, $R(t)=1$).

Chart 3 illustrates the phenomenon of "flattening the curve" for the present model, where the initial R_0 falls from 3.5 to the $R(t)$ of 1.75.

CHART 3

EVOLUTION OF DAILY INCIDENCE OF COVID-19 BASED ON MODEL PROJECTIONS

SOURCE: PREPARED BY THE AUTHOR.

In Chart 3, the red line represents the epidemic's “natural” growth, without any containment measures ($R_0=3.5$), and the blue line represents the daily incidence of infection with a social distancing rate equal to 50% ($R(t)=1.75$).

Notice that the post-intervention curve does indeed “flatten”, but that the epidemic peak shifts forward. This means that, although the number of cases decreases significantly, the epidemic will last longer.


Why does Brazil need to adopt lockdown?

We are still far from controlling this pandemic. The growth rate of the curve is still extremely high, and the model's projections point to a scenario of chaos in the healthcare system.

In lockdowns, which have been adopted in all the countries that have been able to control the epidemic up to the present, people are obliged to stay at home and are subject to sanctions such as fines or even prison. The objective is to reduce the $R(t)$ value to below 1, when one infectious case is not capable of generating another infection. In this situation, the epidemic curve drops drastically. In the case of Brazil, which began the epidemic with $R_0=3.5$, this means increasing social distancing to values above 70%.

The model's projections point to a growing case fatality rate, as observed in Chart 4.

CHART 4

EVOLUTION OF COVID-19 CASE FATALITY RATE BASED ON MODEL PROJECTIONS

SOURCE: PREPARED BY THE AUTHOR.

In Chart 4, CFR stands for case fatality rate, defined as the number of deaths over the number of reported cases. The case fatality rate has increased every day. This is mainly due to the saturation of the hospital system, at which point the probability that people with COVID-19 will die begins to be much higher than that observed among countries that were able to control the epidemic. In some cities in Brazil, people have died because of lack of hospital beds, especially ICU beds, and lack of ventilators.

Brazil has a very high case fatality rates in comparison with other countries. Table 1 shows the current case fatality rate for some Brazilian states.

TABLE 1

CASES, DEATHS AND CASE FATALITY RATE OF COVID-19 - TOTAL BRAZIL AND STATES


	Cases	Deaths	CFR (%)
Brazil	168 331	11 519	6.84
Rio de Janeiro	17 939	1 770	9.87
São Paulo	46 131	37 433	8.12
Amazonas	12 919	1 035	8.01
Ceará	17 599	1 189	6.76
Pernambuco	13 769	1 087	7.89

SOURCE: PREPARED BY THE AUTHOR.

Chart 5 presents a simulation of the model for the number of deaths by age interval, if social distancing rates remain at 50%. The blue bars represent the situation without any mitigation measures, and the red bars, with 50% social distancing.

CHART 5

NUMBER OF DEATHS BASED ON THE MODEL, BY AGE INTERVAL - PROJECTIONS WITHOUT MITIGATION X SOCIAL DISTANCING




SOURCE: PREPARED BY THE AUTHOR.

Chart 6 illustrates a simulation of what would occur under the hypothesis that Brazil adopted lockdown measures and increased social distancing to values greater than 70%.

CHART 6

EVOLUTION OF DAILY INCIDENCE OF COVID-19 BASED ON MODEL PROJECTIONS



SOURCE: PREPARED BY THE AUTHOR.


In Chart 6, the green curve represents the epidemic's "natural" incidence, the red curve, 50% social distancing, and the blue curve, the result of a lockdown with 71% distancing. The chart is on a logarithmic scale to make it easier to see the differences. The rapid exponential drops in the number of new cases per day, represented by the blue curve, show the effectiveness of lockdown measures in controlling the epidemic.

When can quarantine rules be relaxed?

With an average social distancing level of only 50% at the end of May, when the ideal would have been greater than 70%, Brazil is far from controlling this epidemic. Without adopting a widespread and effective lockdown, the projected epidemic curve should reach its peak on July 14, 2020, as observed in Chart 7.

CHART 7

PROJECTION OF THE EPIDEMIC CURVE OF COVID-19 WITHOUT THE ADOPTION OF LOCKDOWN MEASURES



SOURCE: PREPARED BY THE AUTHOR.

If nothing is done, the epidemic peak may reach values of over 65,000 new cases per day at that time, extending until October. Strategies for reopening the country cannot even begin to be discussed at the peak of the epidemic. When will $R(t)$ reach the threshold of 1?


It is known that in every epidemic outbreak of any infection, reproducibility values drop as the fraction of susceptible individuals decreases over time, beginning with the value of R_0 and dropping until there are not enough susceptible individuals to maintain the epidemic's growth curve. This moment is called "herd immunity" (HI). Herd immunity is an explicit function of R_0 and can be calculated as:

$$IR = 1 - \frac{1}{R_0}$$

In the case of a situation without any mitigation measures, in which $R_0=3.5$, herd immunity represents 71% of the susceptible population (thus the need for social distancing greater than 70%). With the current $R(t)$ values, HI will be reached when the fraction of individuals who have already had the disease (variable R_H of the model) reaches 43% in relation to the total population. This should be reached on July 30, 2020, as observed in Chart 8.

CHART 8

PROJECTION OF CASES OF COVID-19 ACCORDING TO THE EVOLUTION OF HERD IMMUNITY



SOURCE: PREPARED BY THE AUTHOR.

From that date onward, any simulation of possible quarantine relaxation strategies should be performed using the model, to avoid recurrence of the epidemic. Before that time, no relaxation of social distancing measures should be discussed. However, it is believed that there would only be some level of reliability if lockdown were decreed, or if discussions about relaxing measures began in mid-September, when the epidemic curve would be at sufficiently low levels.

Conclusions

Brazil is among the countries with the highest rate of COVID-19 dissemination in the world. Initial R_0 values point to a truly catastrophic and unprecedented scenario in the pandemic that still affects many countries.

The mitigation measures adopted in Brazil by the end of May, except for some (still unsuccessful) attempts at lockdown by some states, were extremely timid, and social distancing rates remained far below the ideal. São Paulo, the state most affected by the epidemic, presented social distancing rates below the national average.

Unless the country as a whole adopts lockdown measures, effectively prohibiting people from leaving home and paralyzing all non-essential activities, the likely hypothesis is that Brazil will progress into a worrisome scenario, with a death toll reaching into the hundreds of thousands by the end of the epidemic. In the state of São Paulo alone, the model predicts that in the coming months, the number of new infections per day will surpass 100,000, as was also concluded by a study by researchers at the University of Campinas (Unicamp).³

With the average of 50% distancing rates adopted in the country up to May, the prediction is that the epidemic would reach its peak in the first half of July. If, on the other hand, it was possible to reach the goal of 70% of social isolation, the epidemic curve could drop exponentially, and authorities could begin discussing the reopening of the country.

Finally, it is worth noting that all projections made with the model proposed here are subject to enormous uncertainties, and that the model only allows reliable predictions if its assumptions and the values of its parameters have a sufficient degree of credibility. After all, as stated by eminent statistician George Box, “All models are wrong, but some are useful” (1979, p. 202).

³ Projections made with a mathematical model developed by Campinas State University (Unicamp) indicate that the adoption of mandatory lockdown in the state of São Paulo would be inevitable if the rates of social isolation did not increase significantly in the weeks after May 12, 2020. Toledo, K. (2020), Lockdown será inevitável em SP se isolamento não subir nas próximas semanas, indica estudo (Agência Fapesp). Retrieved on May 17, 2020, from <http://agencia.fapesp.br/lockdown-i-sera-inevitavel-em-sp-se-isolamento-nao-subir-nas-proximas-semanas-indica-estudo/33147/>

References

Bernoulli, D. (1995). Essai d'une nouvelle analyse de la mortalité causée par la petite vérole (Originally published in 1766, translated to English as "An attempt at a new analysis of the mortality caused by smallpox and of the advantages of inoculation to prevent it". In S. Haberman, & T.A. Sibbett (Eds.). *History of actuarial science* (Vol. 8, *Multiple Decrement and Multiple State Models*). London: William Pickering.

Box, G. E. P. (1979). Robustness in the strategy of scientific model building. In R. L. Launer, & G. N. Wilkinson (Eds.). *Robustness in Statistics* (pp. 201–236). Academic Press.

Kermack, W. O., & MacKendrick, A. G. (1927). A contribution to the mathematical theory of epidemics. *Proceedings of the Royal Society*, 115, 700–721.

Massad, E., Menezes, R. X., Silveira, P. S. P., & Ortega, N. R. S. (2004). *Métodos quantitativos em medicina*. São Paulo: Editora Manole.

Lista de Abreviaturas

ABNT – Associação Brasileira de Normas Técnicas	LGPD – Lei Geral de Proteção de Dados Pessoais
AM – Aprendizado de máquina	MCTI – Ministério da Ciência, Tecnologia e Inovações
AMS – Pesquisa Assistência Médico-Sanitária	MS – Ministério da Saúde
ANA – Associação Norte-americana de Enfermagem	NIC.br – Núcleo de Informação e Coordenação do Ponto BR
ANS – Agência Nacional de Saúde Suplementar	OCDE – Organização para a Cooperação e Desenvolvimento Econômico
Anvisa – Agência Nacional de Vigilância Sanitária	OMS – Organização Mundial da Saúde
AP – Aprendizagem profunda	ONU – Organização das Nações Unidas
Cadsus – Cadastramento de Usuários do SUS	Opas – Organização Pan-Americana da Saúde
CBO – Classificação Brasileira de Ocupações	RES – Registro eletrônico em saúde
Cepal – Comissão Econômica para a América Latina e Caribe das Nações Unidas	RNDS – Rede Nacional de Dados em Saúde
Cetic.br – Centro Regional de Estudos para o Desenvolvimento da Sociedade da Informação	RNP – Rede Nacional de Ensino e Pesquisa
CFM – Conselho Federal de Medicina	Rute – Rede Universitária de Telemedicina
CID – Classificação Internacional de Doenças	SADT – Serviço de Apoio à Diagnose e Terapia
CIT – Comissão Intergestores Tripartite	SBIS – Sociedade Brasileira de Informática em Saúde
CGI.br – Comitê Gestor da Internet no Brasil	SUS – Sistema Único de Saúde
CNES – Cadastro Nacional de Estabelecimentos de Saúde	TI – Tecnologia da Informação
CNS – Cartão Nacional de Saúde	TIC – Tecnologia de Informação e Comunicação
COVID-19 – Abreviatura para a doença do coronavírus SARS-CoV-2, de 2019	UBS – Unidade básica de saúde
Datasus – Departamento de Informática do Sistema Único de Saúde	UIT – União Internacional de Telecomunicações
EGD – Estratégia de Governo Digital	Unesco – Organização das Nações Unidas para a Educação, a Ciência e a Cultura
ESD – Estratégia de Saúde Digital	
Gesac – Programa Governo Eletrônico Serviço de Atendimento ao Cidadão	
IA – Inteligência artificial	
IBGE – Instituto Brasileiro de Geografia e Estatística	
ISO – Organização Internacional para Padronização	

List of Abbreviations

ABNT – Brazilian Association of Technical Norms

AI – Artificial Intelligence

AMS – Medical-Sanitary Assistance Survey

ANA – American Nurses Association

ANS – National Regulatory Agency for Private Health Insurance and Plans

Anvisa – Agência Nacional de Vigilância Sanitária

Cadsus – SUS User Registry Information System

CBO – Brazilian Occupational Classification

Cetic.br – Regional Center for Studies on the Development of the Information Society

CFM – Federal Council of Medicine

CGI.br – Brazilian Internet Steering Committee

CIT – Tripartite Intermanagerial Committee

CNES – National Registry of Health Care Facilities

CNS – National Health Cards

COVID-19 – Abbreviation for SARS-CoV-2 Coronavirus disease, 2019

Datasus – SUS Informatics Department

DGS – Digital Government Strategy

DHS – Digital Health Strategy

DL – Deep learning

ECLAC – Economic Commission for Latin America and the Caribbean

EHR – Electronic Health Record

Gesac – Electronic Government Citizen Attendance Service Program

IBGE – Brazilian Institute of Geography and Statistics

ICD – International Statistical Classification of Diseases and Related Health Problems

ICT – Information and Communication Technologies

ISO – International Organization for Standardization

IT – Information Technology

ITU – International Telecommunication Union

LGPD – Brazilian General Data Protection Law

MCTI – Ministry of Science, Technology, and Innovations

ML – Machine learning

MS – Ministry of Health

NIC.br – Brazilian Network Information Center

OECD – Organisation for Economic Co-operation and Development

Paho – Pan American Health Organization

RNDS – National Health Data Network

RNP – National Education and Research Network

Rute – Telemedicine University Network

SADT – Diagnosis and therapy services

SBIS – Brazilian Health Informatics Society

SUS – Unified Health System

UBS – Basic Care Units

UN – United Nations

Unesco – United Nations Educational, Scientific and Cultural Organization

WHO – World Health Organization



Organização
das Nações Unidas
para a Educação,
a Ciência e a Cultura

cetic.br

• Centro Regional de Estudos
• para o Desenvolvimento da
• Sociedade da Informação
• sob os auspícios da UNESCO

nic.br

Núcleo de Informação
e Coordenação do
Ponto BR

cgi.br

Comitê Gestor da
Internet no Brasil

Tel 55 11 5509 3511
Fax 55 11 5509 3512

www.cgi.br
www.nic.br
www.cetic.br