

# Revista da SOCESP

Sociedade de Cardiologia do Estado de São Paulo

## CARDIOLOGIA PRÁTICA

Volume 32 • N. 1 • Janeiro/Março 2022

# Inteligência Artificial em Cardiologia

Editor Chefe

 **Miguel Antonio Moretti**

Coeditores

 **Fabio B. Jatene**

 **José Mariani Junior**



Baixe o app **SOCESP**  
para visualizar a  
publicação





## HW Sistemas, 30 anos pulando inovação!

Desde 1992 prezamos pela qualidade, inovação, eficiência e, principalmente, respeito aos clientes.

## Nossas soluções:

### ECGV6

Registro contínuo de 12 derivações, oferece praticidade para os eletrocardiogramas.

### ERGO 13

teste ergométrico com agilidade. Seu principal diferencial é a facilidade em visualizar todos os dados em uma única tela.

### ERGOMET

capaz de realizar 4 exames: Teste Cardiopulmonar, Teste Ergométrico, Estresse Farmacológico e Eletrocardiograma, é referência para realização de ergoespirometria.

# CHEGOU A HORA DE GARANTIR O SEU LUGAR NO

# GIGANTE

*vagas limitadas*

[www.socesp2022.socesp.org.br](http://www.socesp2022.socesp.org.br)

42<sup>o</sup>  
CONGRESSO  
DA SOCIEDADE  
DE CARDIOLOGIA  
DO ESTADO DE  
SÃO PAULO

SOCESP



# ACADÊMICO E RESIDENTE

# SUA ANUIDADE É GRATUITA!

## PRIMEIRO PASSO

Regularize sua anuidade acessando o site: [www.socesp.org.br](http://www.socesp.org.br)  
Clique em **ESPAÇO ASSOCIADO** e em seguida **RENOVAR A DECLARAÇÃO DE ACADÊMICO, RESIDÊNCIA OU ESTÁGIO.**

## SEGUNDO PASSO

Acesse com o seu login e senha,  
envie sua documentação

## DEVE CONSTAR NO DOCUMENTO

Nome da Instituição, Nome do Aluno, Período Letivo,  
Nome do Curso com data de emissão atual.



## IMPORTANTE!

O prazo para aprovação da documentação é de até 72 horas  
Caso não tenha cadastro deverá preencher todo formulário.

**Realize sua inscrição somente  
após a aprovação do documento**

**42<sup>o</sup>**  
CONGRESSO  
DA SOCIEDADE  
DE CARDIOLOGIA  
DO ESTADO DE  
SÃO PAULO

 **SOCESP**  
SOCIEDADE DE CARDIOLOGIA DO ESTADO DE SÃO PAULO

# BENEFÍCIO SOCIO SOCESP

AQUI, VOCÊ SEMPRE SAI GANHANDO!

Descontos especiais no  
42º Congresso de Cardiologia

DIAS 16, 17 E 18 DE JUNHO DE 2022

42º  
CONGRESSO  
DA SOCIEDADE  
DE CARDIOLOGIA  
DO ESTADO DE  
SÃO PAULO

 SOCESP  
Instituto de Cardiologia do Estado de São Paulo

[www.socesp2022.socesp.org.br](http://www.socesp2022.socesp.org.br)



A Revista da Sociedade de Cardiologia do Estado de São Paulo (ISSN impresso: 0103-8559 e ISSN on line: 2595-4644) é Órgão Oficial da Sociedade de Cardiologia do Estado de São Paulo, editada trimestralmente pela Diretoria de Publicações da SOCESP.

Avenida Paulista, 2073 – Horsa I, 15º andar Conjunto 1512 - Cerqueira Cesar – São Paulo, SP  
CEP 01311-940/Tel: (11) 3181-7429/E-mail: socio@socesp.org.br  
Website: www.socesp.org.br

As mudanças de endereço, a solicitação de números atrasados e as cartas ao Editor deverão ser dirigidas à sede da SOCESP.

É proibida a reprodução total ou parcial de quaisquer textos constantes desta edição sem autorização formal e expressa de seus editores.

Para pedidos de *reprints*, por favor contate: SOCESP – Sociedade de Cardiologia do Estado de São Paulo/  
Diretoria de Publicações  
Tel: (11) 3181-7429/E-mail: socio@socesp.org.br

Coordenação editorial, criação, diagramação, revisão e tradução



**Atha Comunicação e Editora**

Tel.: 11 5087 9502 - 1atha@uol.com.br

Revista da Sociedade de Cardiologia do Estado de São Paulo  
São Paulo – SP, Brasil. V. 1 – 1991 –

1991, **1:** 1 (supl A), 2 (supl A), 3 (supl A)  
1992, **2:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A), 5 (supl A), 6 (supl A)  
1993, **3:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A), 5 (supl A), 6 (supl A)  
1994, **4:** 1 (supl A), 2 (supl A), 3 (supl A), 3 (supl B), 4 (supl A), 5 (supl A), 6 (supl A)  
1995, **5:** 1 (supl A), 2 (supl A), 3 (supl B), 4 (supl A), 5 (supl A), 6 (supl A)  
1996, **6:** 1 (supl A), 2 (supl A), 3 (supl A), 3 (supl B), 4 (supl A), 5 (supl A), 6 (supl A)  
1997, **7:** 1 (supl A), 2 (supl A), 3 (supl A), 3 (supl B), 4 (supl A), 5 (supl A), 6 (supl A)  
1998, **8:** 1 (supl A), 2 (supl A), 3 (supl A), 4 (supl A), 4 (supl B), 5 (supl A), 6 (supl A)  
1999, **9:** 1 (supl A), 2 (supl A), 3 (supl A), 3 (supl B), 4 (supl A), 5 (supl A), 6 (supl A)  
2000, **10:** 1 (supl A), 2 (supl A), 3 (supl A), 3 (supl B), 4 (supl A), 5 (supl A), 6 (supl A)  
2001, **11:** 1 (supl A), 2 (supl A), 3 (supl A), 3 (supl B), 4 (supl A), 5 (supl A), 6 (supl A)  
2002, **12:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A), 5 (supl A), 6 (supl A)  
2003, **13:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A), 5 (supl A), 6 (supl A)  
2004, **14:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A), 5 (supl A), 6 (supl A)  
2005, **15:** 1 (supl A), 2 (supl A), 3 (supl A), 4 (supl A), 5 (supl A), 5 (supl B), 6 (supl A)  
2006, **16:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A)  
2007, **17:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A)  
2008, **18:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A)  
2009, **19:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A)  
2010, **20:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A)  
2011, **21:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A)  
2012, **22:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A)  
2013, **23:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A)  
2014, **24:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A)  
2015, **25:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A)  
2016, **26:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A)  
2017, **27:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A)  
2018, **28:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A)  
2019, **29:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A)  
2020, **30:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A), 4 (supl A)  
2021, **31:** 1 (supl A), 2 (supl A), 2 (supl B), 3 (supl A),  
2022, **32:** 1 (supl A)

ISSN 0103-8559 / 2595-4644  
RSCESP 72594

CDD<sub>i6</sub> 616.105  
NLM W1

WG100  
CDU 616.1(05)

## DIRETORIA DA SOCIEDADE DE CARDIOLOGIA DO ESTADO DE SÃO PAULO/Biênio 2022 -2023

**Presidente**  
Ieda Biscegli Jatene  
**Vice-Presidente**  
Alexandre Antonio C. Abizaid  
**1ª Secretária**  
Maria Cristina de Oliveira Izar  
**2ª Secretária**  
Auristela Isabel de Oliveira Ramos  
**1º Tesoureiro**  
Ricardo Pavanello  
**2ª Tesoureira**  
Salete Aparecida da Ponte Nacif  
**Diretor de Publicações**  
Miguel Antonio Moretti

**Diretor de Qualidade Assistencial**  
Carlos Gun  
**Diretor Científico**  
Felix José Alvarez Ramires  
**Diretor de Comunicação**  
Marcelo Franken  
**Diretor de Relações Institucionais e Governamentais**  
Renato Azevedo Júnior  
**Diretor de Regionais**  
Andrei Carvalho Sposito  
**Diretor de Promoção e Pesquisa**  
Luciano Ferreira Drager  
**Diretor do Centro de Treinamento em Emergências**  
Agnaldo Piscopo

**Coordenadores do Centro de Memórias**  
Alberto Francisco Piccolotto Naccarato  
Ronaldo Fernandes Rosa  
**Coordenadores do Projeto Insuficiência Cardíaca**  
Dirceu Rodrigues Almeida  
Múcio Tavares de Oliveira Junior  
**Coordenadores do Projeto Infarto**  
Antonio Claudio do Amaral Baruzzi  
Jorge Zarur Neto  
Roberta Saretta  
**Coordenadora do Projeto SOCESP Mulher**  
Líliá Nigro Maia

## DIRETORIA DAS REGIONAIS DA SOCIEDADE DE CARDIOLOGIA DO ESTADO DE SÃO PAULO/Biênio 2022 -2023

### ABCDM - Biênio 2022 -2023

**Presidente**  
Kamal Yazbek Junior  
**Diretor Científico**  
Roberto Andres Gomes Douglas  
**Primeiro Secretário**  
José Alexandre da Silveira  
**Segundo Secretário**  
Fabio José Matheus

### ARAÇATUBA - Biênio 2022 -2023

**Presidente**  
Richard Crevelaro  
**Diretor Científico**  
Marco Antonio Coelho Goiato  
**Primeiro Secretário**  
Paulo Francisco De Mesquita Barros  
**Segunda Secretária**  
Helena Cordeiro Barroso

### ARARAQUARA - Biênio 2022 -2023

**Presidente**  
Cecília Meirelles Barros  
**Diretora Científica**  
Argenzia Mestria Bonfa  
**Primeiro Secretário**  
Edson Akira Kusumoto  
**Segundo Secretário**  
Flavio Magnani Lauand

### ARARAS - Biênio 2022 -2023

**Presidente**  
José Joaquim Fernandes Raposo  
**Diretor Científico**  
José Luiz Ferreira dos Santos  
**Primeiro Secretário**  
Valentim Patrício Valério  
**Segundo Secretário**  
Fernando Candido Martins

### BAURU - Biênio 2022 -2023

**Presidente**  
Alexandre Volney Villa  
**Diretor Científico**  
Edmir José Sia Filho  
**Primeiro Secretário**  
Roberto Chaim Berber  
**Segundo Secretário**  
Gustavo Buchalla

### BOTUCATU - Biênio 2022 -2023

**Presidente**  
Flavio de Souza Brito  
**Diretor Científico**  
Ricardo Mattos Ferreira  
**Primeiro Secretário**  
Renato Teixeira  
**Segundo Secretário**  
Marcos Mitsuo Seki

### CAMPINAS - Biênio 2022 -2023

**Presidente**  
Sérgio Luiz Polydoro

**Diretora Científica**  
Carla Patricia Da Silva E Prado

**Primeiro Secretário**  
Fernando Mello Porto

**Segundo Secretário**  
Hugo Pazianotto

### FRANCA - Biênio 2022 -2023

**Presidente**  
Hélio Rubens Crialenzi  
**Diretor Científico**  
Luiz Alfredo Husemann Patti  
**Primeiro Secretário**  
Rossini Rodrigues Machado  
**Segundo Secretário**  
Ronaldo Américo Mandel

### JUNDIAÍ - Biênio 2022 -2023

**Presidente**  
Tarcio Figueiredo Silva  
**Diretor Científico**  
João Paulo de Mello Medeiros  
**Primeiro Secretário**  
Dennys Marcel Sanches Martins  
**Segundo Secretário**  
Marco Antonio Dias

### MARÍLIA - Biênio 2022 -2023

**Presidente**  
João Carlos Moron Saes Braga  
**Diretor Científico**  
Alexandre Rodrigues  
**Primeiro Secretário**  
André dos Santos Moro  
**Segundo Secretário**  
Marcelo Tadeu Blumer Peron

### OSASCO - Biênio 2022 -2023

**Presidente**  
Marcos Valerio Coimbra de Resende  
**Diretor Científico**  
André Dabarian  
**Primeira Secretária**  
Ana Maria Rocha Pinto e Silva  
**Segunda Secretária**  
Valeria Fontenelle Angelim Pereira

### PIRACICABA - Biênio 2022 -2023

**Presidente**  
Daniel de Araujo Collaco  
**Diretora Científica**  
Juliana Barbosa Previtalli  
**Primeiro Secretário**  
Dairo Bicudo Piai Junior  
**Segundo Secretário**  
Luis Gustavo Ramos

### PRESIDENTE PRUDENTE - Biênio 2022 -2023

**Presidente**  
Antonio Luiz Oliveira Rosas Junior  
**Diretor Científico**  
Nina Azevedo de Medeiros Couto

**Primeiro Secretário**  
Romulo Cesar Arnal Bonini  
**Segundo Secretário**  
Luciane Schadeck

### RIBEIRÃO PRETO - Biênio 2022 -2023

**Presidente**  
Divino Luiz Rattis Batista  
**Diretor Científico**  
Pedro Velloso Schwartzmann  
**Primeiro Secretário**  
Thiago Florentino Lascala  
**Segundo Secretário**  
Leonardo Pippa Gadioli

### SANTOS - Biênio 2022 -2023

**Presidente**  
Leonardo Martins Barroso  
**Diretor Científico**  
Fábio de Freitas Guimarães Guerra  
**Primeiro Secretário**  
Marcelo Plinik  
**Segundo Secretário**  
Carlos Eduardo Mendonca Tome

### São Carlos - Biênio 2022 -2023

**Presidente**  
Rodrigo Santos Aguiar  
**Diretora Científica**  
Ana Candida A. Verzola de Castro  
**Primeira Secretária**  
Meliza Goi Roscani  
**Segundo Secretário**  
Carlos Alberto Rovina Almeida

### SÃO JOSÉ DO RIO PRETO - Biênio 2022 -2023

**Presidente**  
Thiago Baccili Cury Megid  
**Diretor Científico**  
Luiz Fernando Dal Col  
**Primeiro Secretário**  
Elzo Thiago Brito Mattar  
**Segunda Secretária**  
Mariana Facio Jabur de Goes

### SOROCABA - Biênio 2022 -2023

**Presidente**  
Fábio Lourenço Moraes  
**Diretor Científico**  
Péricles Sidnei Salmazo  
**Primeiro Secretário**  
Juliana Buchmann Pereira  
**Segundo Secretário**  
Fernando Côrtes Remisio Fiquinha

### VALE DO PARAÍBA - Biênio 2022 -2023

**Presidente**  
Marcelle Sá Machado de Araújo  
**Diretora Científica**  
Yuri Gollino  
**Primeiro Secretário**  
Luiz Fernando Fagundes de Gouveia Filho  
**Segunda Secretária**  
Luana Lorena Moreira



Miguel Antonio Moretti  
Diretor de Publicações

A inteligência artificial (IA) representa uma nova era da informática, onde os computadores se tornam integrados e parte da experiência de nossas vidas. São ferramentas utilizadas não só na construção e compartilhamento de dados, mas também na formulação e ajuste de modelos de decisão nos diferentes domínios do conhecimento humano.

Diversas atividades relacionadas à saúde, incluindo a cardiologia, já contam com os serviços da IA no auxílio diagnóstico e terapêutico da prática médica. Por isso, nessa primeira edição, de 2022, da revista da SOCESP, trouxemos artigos sobre como a IA já está inserida na prática da cardiologia e de como devemos e podemos nos apoderar dessa tecnologia sem romper com as características humanizadas do atendimento e do acolhimento médico. Pois, apesar da evolução em relação ao potencial de facilitar a decisão médica, há também preocupações quanto ao papel do médico na era da IA. E sob esses aspectos, os autores dessa edição trouxeram importantes informações que nos auxiliarão não só no entendimento da IA mas também na jornada por essa estrada.

Sobre a IA podemos dizer que ela representa um grupo de diferentes métodos que proporcionam a combinação de modelos matemáticos e da computação, no sentido de produzir algoritmos que possam imitar a inteligência humana. Estes algoritmos não são inteligentes “per se”, mas atuam no auxílio para explorar e analisar conjuntos de dados amplos e complexos. A IA serve como um apoio para situações em que as limitações da capacidade intelectual humana dificultam a manipulação de elevados volumes de dados e informações, ou mesmo para analisar estes dados de forma acurada e reprodutível.

A utilização da IA na cardiologia está deixando a esfera teórica para se tornar uma realidade prática com diversas aplicações. E nesse ponto eu destaco o excelente trabalho dos autores que colaboraram para os artigos aqui publicados. E deixo meus parabéns aos coeditores, Prof. Dr. Fábio Biscegli Jatene e Prof. Dr. José Mariani Junior, responsáveis por mais essa importante revista na família de publicações da SOCESP.

Tenho certeza de que será uma boa e proveitosa leitura.



## Inteligência Artificial em Cardiologia

- INTELIGÊNCIA ARTIFICIAL, DEEP LEARNING, MACHINE LEARNING, REDES NEURAIS NA MEDICINA E BIOMARCADORES VOCAIS: CONCEITOS, ONDE ESTAMOS E PARA ONDE VAMOS ..... 11  
*ARTIFICIAL INTELLIGENCE, DEEP LEARNING, MACHINE LEARNING, NEURAL NETWORKS IN MEDICINE AND VOCAL BIOMARKERS: CONCEPTS, WHERE WE ARE, AND WHERE WE ARE GOING*  
Rosângela Monteiro, Guilherme de Castro Machado Rabello, Francismar Vidal de Arruda Junior, Fabio Biscegli Jatene  
<http://dx.doi.org/10.29381/0103-8559/2022320111-7>
- INTELIGÊNCIA ARTIFICIAL PARA MONITORAMENTO REMOTO DO PACIENTE ..... 18  
*ARTIFICIAL INTELLIGENCE FOR REMOTE PATIENT MONITORING*  
Roberto Vieira Botelho, Sameer Mehta, Fausto Feres, Francisco Fernández, Wladimir Rezende  
<http://dx.doi.org/10.29381/0103-8559/2022320118-26>
- APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL EM IMAGEM CARDIOVASCULAR: EM TOMOGRAFIA COMPUTADORIZADA E RMN ..... 27  
*APPLICATION OF ARTIFICIAL INTELLIGENCE IN CARDIAC IMAGING: COMPUTED TOMOGRAPHY AND MAGNETIC RESONANCE IMAGING*  
Gilberto Szarf, Cesar H. Nomura  
<http://dx.doi.org/10.29381/0103-8559/2022320127-30>
- APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL EM IMAGEM CARDIOVASCULAR: CLASSIFICAÇÃO AUTOMÁTICA DE IMAGENS DE RADIOGRAFIA DE TÓRAX..... 31  
*APPLICATION OF ARTIFICIAL INTELLIGENCE IN CARDIOVASCULAR IMAGING: AUTOMATIC CLASSIFICATION OF CHEST RADIOGRAPHY IMAGES*  
Marco Antonio Gutierrez, Diego Armando Cardona Cardenas, Karem Daiane Marcomini, Agma Juci Machado Traina, Ramon Alfredo Moreno, José Eduardo Krieger  
<http://dx.doi.org/10.29381/0103-8559/2022320131-8>
- APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL EM IMAGEM CARDIOVASCULAR: EM ECOCARDIOGRAFIA ..... 39  
*APPLICATION OF ARTIFICIAL INTELLIGENCE IN CARDIOVASCULAR IMAGING : IN ECHOCARDIOGRAPHY*  
Edgar Daminello, Paulo Pinto Alves Campos Vieira, Cláudio Henrique Fischer, Marcelo Luiz Campos Vieira  
<http://dx.doi.org/10.29381/0103-8559/2022320139-44>
- APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL EM IMAGEM CARDIOVASCULAR: EM MÉTODOS GRÁFICOS E ELETROCARDIOGRAFIA..... 45  
*APPLICATION OF ARTIFICIAL INTELLIGENCE IN CARDIOVASCULAR IMAGING: GRAPHICAL METHODS AND ELECTROCARDIOGRAPHY*  
Camilla Rocon de Lima Andretta  
<http://dx.doi.org/10.29381/0103-8559/2022320145-50>
- INTELIGÊNCIA ARTIFICIAL EM CARDIOLOGIA INTERVENCIONISTA..... 51  
*ARTIFICIAL INTELLIGENCE IN INTERVENTIONAL CARDIOLOGY*  
Pedro A. Lemos  
<http://dx.doi.org/10.29381/0103-8559/2022320151-4>
- INTELIGÊNCIA ARTIFICIAL EM CIRURGIA CARDIOVASCULAR ..... 55  
*ARTIFICIAL INTELLIGENCE IN CARDIOVASCULAR SURGERY*  
Omar Asdrubal Vilca Mejia, Luis Roberto Palma Dallan  
<http://dx.doi.org/10.29381/0103-8559/2022320155-9>
- INTELIGÊNCIA ARTIFICIAL NA TOMADA DE DECISÃO CLÍNICA EM MEDICINA CARDIOVASCULAR ..... 60  
*ARTIFICIAL INTELLIGENCE IN CLINICAL DECISION MAKING IN CARDIOVASCULAR MEDICINE*  
Pedro Gabriel Melo de Barros e Silva, Tiago Frigini, Renato Delascio Lopes, Bernardo Baptista da Cunha Lopes, Ariane V. Scarlatelli Macedo, Bruno R. Nascimento, Valter Furlan, Antonio Luiz P. Ribeiro  
<http://dx.doi.org/10.29381/0103-8559/2022320160-70>

# INTELIGÊNCIA ARTIFICIAL, DEEP LEARNING, MACHINE LEARNING, REDES NEURAIAS NA MEDICINA E BIOMARCADORES VOCAIS: CONCEITOS, ONDE ESTAMOS E PARA ONDE VAMOS

*ARTIFICIAL INTELLIGENCE, DEEP LEARNING, MACHINE LEARNING, NEURAL NETWORKS IN MEDICINE AND VOCAL BIOMARKERS: CONCEPTS, WHERE WE ARE, AND WHERE WE ARE GOING*



Clique para acessar  
o Podcast

Rosângela Monteiro<sup>1</sup>  
Guilherme de Castro  
Machado Rabello<sup>1</sup>  
Francismar Vidal de Arruda  
Junior<sup>2</sup>  
Fabio Biscegli Jatene<sup>1</sup>

1. InovaInCor. Instituto do Coração.  
Hospital das Clínicas da Faculdade  
de Medicina da Universidade de São  
Paulo (InCor-HCFMUSP). São Paulo,  
SP, Brasil.

2. Escola Paulista de Medicina da  
Universidade Federal de São Paulo  
(EPM/UNIFESP), São Paulo, SP, Brasil.

Correspondência:  
Fabio B. Jatene  
fabiojatene@incor.usp.br

## RESUMO

Na última década, a aplicação da inteligência artificial (IA) teve avanços notáveis, em todas as áreas do conhecimento. Diversas soluções tecnológicas baseadas em IA têm sido propostas na área médica, buscando tornar o diagnóstico e o tratamento cada vez mais assertivos e seguros. O número de artigos publicados cresce vertiginosamente, e a maioria reporta estudos iniciais, provas de conceito, mas vários já têm demonstrado aplicações clínicas estruturadas. Os profissionais da saúde devem, portanto, assumir um papel de liderança na decisão de onde aplicar e como interpretar essa tecnologia. Este artigo apresenta conceitos básicos de IA, aprendizado de máquina (*machine learning*), aprendizado profundo (*deep learning*), redes neurais em Medicina e biomarcadores vocais.

**Descritores:** Inteligência Artificial; Aprendizado Profundo; Aprendizado de Máquina; Redes Neurais de Computação; Biomarcadores; Voz; Medicina.

## ABSTRACT

*In the last decade, the application of artificial intelligence (AI) has made remarkable advances in all knowledge areas. Several technological solutions based on AI have been proposed in the medical field, seeking to make diagnosis and treatment increasingly assertive and safe. The number of published articles is growing dramatically, and most report initial studies and proofs of concept, but several have already demonstrated structured clinical applications. Healthcare professionals must therefore take a leading role in deciding where to apply and how to interpret this technology. This article presents basic concepts of AI, machine learning, deep learning, neural networks in medicine, and vocal biomarkers.*

**Keywords:** Artificial Intelligence; Deep Learning; Machine Learning; Neural Networks, Computer; Biomarkers; Voice; Medicine.

## INTELIGÊNCIA ARTIFICIAL, DEEP LEARNING E MACHINE LEARNING

Na última década, a aplicação da inteligência artificial (IA) teve avanços notáveis, em todas as áreas do conhecimento. Se antes a IA parecia uma tecnologia distante, hoje está presente em nosso cotidiano, em distintas situações, passando muitas vezes despercebida. A IA está presente em serviços bancários, nos aplicativos de rotas, que cruzam informações de fontes diversas para encontrar os melhores caminhos, otimizando tempo e evitando problemas no trânsito. Outro exemplo são as lojas virtuais, que empregam IA para fornecer uma melhor experiência aos consumidores, identificando preferências com base nos seus comportamentos e

fazendo sugestões de acordo com hábitos de consumo. As operadoras de cartão de crédito também utilizam soluções com IA para reduzir riscos e fraudes, fazendo uma leitura em tempo real do comportamento do comprador junto ao emissor do cartão, identificando padrões de gastos.

Na área da Saúde não têm sido diferente, a IA vem sendo usada em diversos processos, como, por exemplo, na gestão de leitos, predizendo tempo de internação e desfechos clínicos. Além disso, diversas soluções tecnológicas baseadas em IA têm sido propostas, buscando tornar o diagnóstico e o tratamento cada vez mais assertivos e seguros.

As publicações científicas na área vêm crescendo de forma exponencial, para ser ter uma ideia, apenas no ano de 2021, mais de 28 mil artigos relacionados à IA foram

indexados no PubMed.<sup>1</sup> A maioria desses artigos reporta estudos iniciais, provas de conceito, mas vários já têm demonstrado aplicações clínicas estruturadas.

Aproximadamente 30% dos dados armazenados em todo o mundo são gerados pela assistência médica. Esses dados se revestem de grande valor clínico, financeiro e operacional e devem ser aplicados na construção de estratégias na área da Saúde.<sup>2</sup> Além disso, os dados não são mais coletados apenas no ambiente médico-hospitalar. A proliferação de sensores móveis, como relógios inteligentes (*smartwatches*) e outros dispositivos vestíveis (*wearables*) – que vêm criando oportunidades de monitoramento inéditas – exigirá que a equipe clínica monitore, interprete e responda a fluxos adicionais de dados biomédicos coletados remotamente e automaticamente.<sup>3</sup>

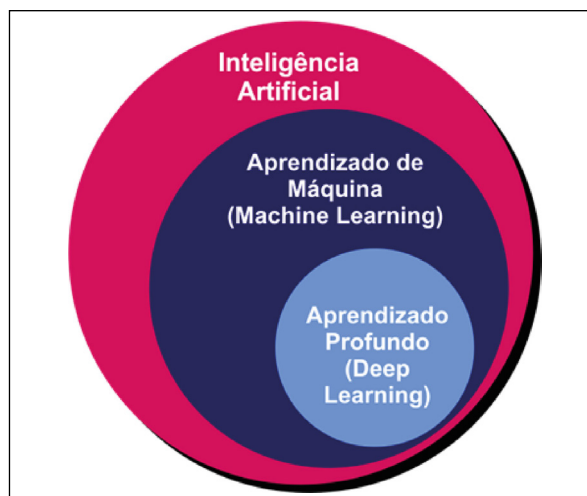
À medida que a importância da Ciência de Dados cresce na prática clínica, aumenta a necessidade de que os profissionais da Saúde compreendam e incorporem conceitos como IA, aprendizado de máquina (*machine learning* ou ML) e aprendizado profundo (*deep learning* ou DL). Nesse contexto, se insere esse trabalho, que apresenta os princípios básicos da IA, o *status* atual e as perspectivas futuras de sua aplicação na Medicina, em especial na Cardiologia.

O conceito de IA foi proposto em 1956, por um cientista da computação americano John McCarthy, durante um seminário em *Dartmouth College*, em Hanover (New Hampshire, EUA), que reuniu pesquisadores renomados dedicados ao estudo da inteligência.<sup>2</sup> O termo IA nasce da ambição de capacitar computadores para realizar tarefas desempenhadas pelo cérebro humano. A estratégia utilizada, na maioria das vezes, é baseada em aprendizado supervisionado da máquina. Um conjunto de dados de entrada é decisivo para obter dados de resposta, expressos basicamente em função de probabilidades, gerando um parâmetro ou um número. Segundo Morsh,<sup>4</sup> IA são máquinas e algoritmos com capacidade de dar respostas racionais a situações diversas e cada vez mais complexas – o que inclui demandas da Medicina. Assim, a IA em Medicina é o uso de computadores que, analisando um grande volume de dados e seguindo algoritmos definidos por especialistas da área, são capazes de propor soluções para problemas médicos.<sup>5</sup>

Em outras palavras, é fazer com que máquinas reproduzam tarefas que, atualmente, são feitas por nós. Está relacionada à capacidade das máquinas serem capazes de aprender, identificar, perceber e decidir. Para tanto, é necessário grande volume de dados de qualidade, que apresentem consistência, integridade, precisão e conformidade.

A IA é um conceito amplo, que possui várias subáreas, dentre elas o ML, que é uma parte da IA, e o DL é uma parte do ML.<sup>6</sup> (Figura 1)

Os sistemas de IA são regidos por algoritmos usando técnicas como ML e DL para demonstrar “comportamento inteligente.”<sup>7</sup> Com relação ao ML, um computador “aprende” quando o *software* é capaz de prever e reagir com sucesso ao desdobramento de cenários com base em resultados anteriores. O ML é o processo pelo qual os computadores desenvolvem o reconhecimento de padrões ou a capacidade de aprender continuamente ou fazer previsões com base em dados, e podem fazer ajustes sem serem especificamente programados para isso. Este processo automatiza, com



**Figura 1.** Representação da relação entre inteligência artificial, aprendizado de máquina e aprendizado profundo. Adaptado de Kodera et al.<sup>6</sup>

eficiência, o processo de construção de modelos analíticos e permite que as máquinas se adaptem a novos cenários de forma independente.

Morsh<sup>4</sup> elenca potenciais vantagens da aplicação da IA na Medicina, dentre elas, destacam-se:

- Rápida pesquisa, recuperação e correlação de dados;
- Monitoramento remoto de pacientes em tempo real;
- Otimização da classificação de risco de pacientes em tempo real;
- Identificação de tendências em populações específicas;
- Previsões quanto aos riscos de doenças;
- Composição de tratamentos personalizados, elaborados de acordo com o histórico do paciente;
- Coleta, armazenamento e cruzamento automático de dados para melhorar a precisão e agilidade dos diagnósticos;
- Realização de cirurgias à distância, dando suporte a robôs;
- Suporte ao autocuidado/autonomia, fornecendo informações assertivas ao paciente;
- Favorece a transformação digital em hospitais e clínicas médicas;
- Cálculo da dosagem correta de medicamentos, bem como identificação de interação medicamentosa;
- Melhoria da produtividade dos funcionários, que passam a contar com a automação de tarefas repetitivas;
- Agilidade no diagnóstico através de imagens coletadas em exames; e
- Apoio à gestão de consultórios, clínicas e hospitais.

A tecnologia de IA lida com enormes quantidades de informações, apresentando um potencial incalculável para trazer grandes benefícios à medicina cardiovascular.<sup>8</sup> O campo da medicina cardiovascular utiliza uma grande variedade e quantidade de biosinais, por isso existem muitas situações em que a IA pode contribuir.<sup>9</sup> A IA vem demonstrando aplicações promissoras na área cardiológica e vem sendo avaliadas em diferentes frentes, como no monitoramento remoto de pacientes crônicos por meio de aplicativos. Talvez as aplicações mais maduras estejam no campo do apoio ao diagnóstico médico, com a automatização de interpretação de imagens e traçados por meio do reconhecimento de padrões e identificação de anormalidades em exames

como eletrocardiograma (ECG), ecocardiograma, tomografia computadorizada, ressonância magnética e medicina nuclear. Outra vertente que vem crescendo está relacionada aos algoritmos de predição de risco, empregados para prever a mortalidade e complicações após cirurgia cardiovascular, implante de TAVI e outros procedimentos.

Se por um lado as perspectivas de aplicação da IA em Medicina são gigantescas, por outro lado, vemos um desafio proporcional nos riscos de uso indevido ou má interpretação se não entendermos completamente os recursos, as armadilhas e os aspectos éticos relacionados.<sup>6,9</sup>

Souza Filho et al.,<sup>10</sup> destacam que nem tudo são flores e ainda temos vários desafios a serem superados para efetiva aplicação de IA na Saúde, são eles: 1. limites éticos de uso (uso indevido com interesses outros que não a melhoria de desfechos clínicos e processos); 2. melhoria do conhecimento de matemática; 3. aquisição de dados confiáveis (banco de dados ou biblioteca representativos dos problemas a serem estudados, coletados e processados adequadamente); 4. segurança e confidencialidade dos dados; 5. necessidade de colaboração entre instituições (permite a construção de bancos saudáveis mais robustos); 6. atenção a erros (falhas devido à baixa qualidade dos dados); 7. gestão de cuidados baseados em dados.

## REDES NEURAIS NA MEDICINA

O mundo da ciência da computação e da IA, que inicialmente encontrou pouca atenção na área médica, está trazendo novas aplicações com diferentes técnicas: como ML, DL e redes neurais - para revolucionar a Medicina moderna. A área da cardiologia também está se beneficiando dessa revolução tecnológica.<sup>11-16</sup>

Como já abordado no item anterior, a IA através de suas diferentes abordagens para processar os dados (como ML e DL) tem expandido seus horizontes de aplicações na Medicina,<sup>17-19</sup> notadamente em áreas onde o uso de algoritmos de análise de dados já se encontra maduro. Vemos uma tendência de crescimento de *softwares* e algoritmos de identificação e análise de imagens em exames diagnósticos, por exemplo.

Entretanto, mesmo com todo o avanço dos algoritmos de IA para processar os dados, uma das limitações inerentes à computação de grandes quantidades de informações é o próprio *hardware*. Determinados processos computacionais exigem crescente poder de memória e processadores mais velozes. Isto inibe avanços em áreas onde aplicações médicas dependem de modelos preditivos ou analíticos complexos.

Modelos de redes neurais artificiais (RNA) funcionam nos princípios da rede neural biológica, onde cada neurônio está conectado com outros neurônios. Ele tem duas partes, ou seja, os dendritos e o axônio.<sup>20</sup>

No modelo biológico, sabemos que os dendritos atuam como receptores e o axônio como transmissor de informações. O núcleo do neurônio contém a informação que deve ser transferida.

As RNAs consistem em uma camada de entrada, camadas ocultas e camada de saída, enquanto as informações são alimentadas no modelo através da camada de entrada, processadas pelas camadas ocultas e enviadas da camada de saída. (Figura 2)

As RNAs estão ganhando importância no campo da

modelagem preditiva devido à sua capacidade de modelar relacionamentos não lineares em um conjunto de dados de alta dimensão. Modelos de RNA são capazes de prever uma relação complexa entre variáveis, o que não é possível com outros modelos, como modelos de regressão logística.

Devido à sua capacidade de analisar os dados com relação não linear, os modelos de RNA estão sendo amplamente utilizados na área de diagnóstico, prognóstico, classificação, predição e análise de sobrevida.

A Tabela 1 compara os modelos de redes neurais artificiais e os modelos tradicionais como os modelos de regressão logística.<sup>13</sup>

Os modelos de rede neural são usados no processamento de imagens em Radiologia, Medicina Nuclear, Dermatologia e Patologia. Modelos de RNA são aplicados para interpretar e classificar os sinais de eletroencefalograma (EEG) e ECG. Em relação aos ECGs, alguns trabalhos recentes se destacam, como o de Bos et al.<sup>20</sup>

Neste trabalho de Bos et al.,<sup>20</sup> a síndrome do QT longo (LQTS) é considerada como potencial alvo do uso da RNA por meio da IA e aprendizado de máquina, usando um ECG de 12 derivações aprimorado por IA (AI-ECG), para distinguir pacientes com síndrome do QT longo daqueles que não têm a síndrome. Sabemos que a LQTS é caracterizada pelo prolongamento do intervalo QT e está associada a um risco aumentado de morte súbita cardíaca. No entanto, embora o prolongamento do intervalo QT seja

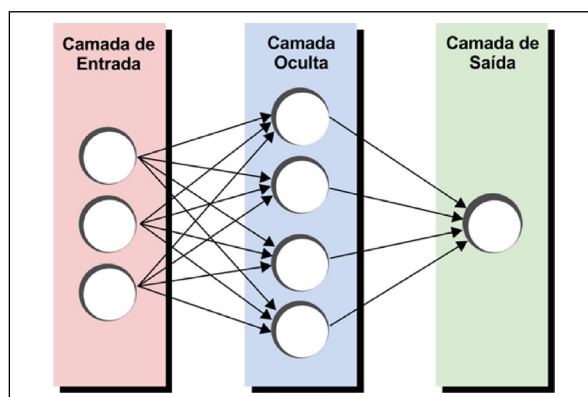


Figura 2. Visão esquemática da estrutura da rede neural artificial, com camada de entrada, uma ou mais camadas ocultas e uma camada de saída.

Tabela 1. Comparação entre RNA e modelos estatísticos tradicionais. (Adaptado de Renganathan<sup>13</sup>).

Parâmetros Capacidade de analisar relações não lineares	Rede neural artificial
Capacidade de lidar com variáveis independentes correlacionadas	Superior aos modelos estatísticos tradicionais
Precisão de classificação	Maior do que nos modelos estatísticos tradicionais
Interpretação de coeficientes/pesos	Mais difícil do que nos modelos estatísticos tradicionais
Chances de <i>overfitting</i>	Maiores do que nos modelos estatísticos tradicionais

a característica marcante da SQTL, aproximadamente 40% dos pacientes com SQTL geneticamente confirmada têm um QT normal corrigido (QTc) em repouso. Distinguir pacientes com SQTL daqueles com QTc normal é importante para diagnosticar corretamente a doença, implementar medidas preventivas simples de SQTL e iniciar terapia profilática, se necessário.

Uma rede neural convolucional multicamada foi usada para classificar os pacientes com base em um ECG de 10 segundos e 12 derivações, ECG aprimorado por IA (ECG-AI). A rede neural convolucional foi treinada em 60% dos pacientes, validada em 10% dos pacientes e testada nos demais pacientes (30%). Os resultados foram muito promissores. O ECG-AI foi capaz de distinguir pacientes com SQTL oculta eletrocardiograficamente daqueles que receberam alta sem diagnóstico de SQTL e fornecer uma antecipação de teste pré-genético com precisão de quase 80% do status do genótipo de SQTL. Este modelo pode auxiliar na detecção de SQTL em pacientes que se apresentam a uma clínica cardiológica e, com validação, pode ser o trampolim para

ferramentas semelhantes a serem desenvolvidas para uso na população em geral.

Outros artigos têm buscado avaliar o emprego da RNA em diferentes cenários de pacientes cardiológicos, como destacamos na Tabela 2.

Embora a IA seja, muitas vezes, vista como um conceito futurista e distante, a verdade é que esta tecnologia já está sendo utilizada em todo o tipo de áreas, incluindo a Cardiologia.<sup>11</sup> Devido à digitalização de grandes quantidades de dados, ao desenvolvimento de algoritmos de ML e às melhorias no poder do computador nas últimas décadas, a IA pode fornecer excelentes oportunidades para automação de tarefas, aplicação de medicina de precisão ou progresso de pesquisa por meio da detecção de padrões complexos em medicina bancos de dados. E, neste sentido, a RNA será uma poderosa adição ao processo de processamento de larga quantidade de dados dos pacientes, potencializando os algoritmos e modelos preditivos para auxílio no diagnóstico e na tomada de decisão clínica.

**Tabela 2.** Artigos e aplicações das redes neurais artificiais.

Artigo	Aplicação
Artificial intelligence and machine learning in arrhythmias and cardiac electrophysiology. <sup>21</sup>	Na eletrofisiologia cardíaca, começamos a ver como a IA está mudando os mecanismos tradicionais para detectar e diagnosticar doenças, prever os resultados dos pacientes e entender e caracterizar os processos da doença. Ainda há um trabalho significativo para entender melhor os recursos, as armadilhas e a implantação apropriada da IA para que ela seja integrada clinicamente
An artificial neural network approach for predicting hypertension using NHANES data. <sup>22</sup>	Este trabalho enfoca um modelo de classificação de rede neural para estimar a associação entre sexo, raça, IMC, idade, tabagismo, doença renal e diabetes em pacientes hipertensos. Também mostra que técnicas de redes neurais artificiais aplicadas a grandes conjuntos de dados clínicos podem fornecer uma abordagem significativa baseada em dados para categorizar pacientes para gestão de saúde populacional e suporte no controle e detecção de pacientes hipertensos, o que faz parte dos fatores críticos para doenças do coração
Predicting neurological outcome after out-of-hospital cardiac arrest with cumulative information; development and internal validation of an artificial neural network algorithm. <sup>23</sup>	Neste estudo exploratório, as RNAs forneceram acurácia prognóstica de boa a excelente na previsão de resultados neurológicos em pacientes comatosos após parada cardíaca extra-hospitalar usando variáveis clínicas e biomarcadores dos primeiros três dias de terapia intensiva
Developing neural network models for early detection of cardiac arrest in emergency department. <sup>24</sup>	A vigilância automatizada de paradas cardíacas seria útil em departamentos de emergência superlotados. O objetivo deste estudo é desenvolver e testar classificadores de redes neurais artificiais (RNA) para detecção precoce de pacientes com risco de parada cardíaca em departamentos de emergência
Development and validation of an artificial neural network algorithm to predict mortality and admission to hospital for heart failure after myocardial infarction: a nationwide population-based study. <sup>25</sup>	A identificação de pacientes com alto risco de desenvolver insuficiência cardíaca ou morte após infarto do miocárdio pode resultar em terapias personalizadas e monitoramento pela alocação de recursos para aqueles com maior risco
Contribution of neural networks in the diagnosis and treatment of cardiac arrhythmia. <sup>26</sup>	Encontrar um tratamento eficaz para a arritmia tornou-se um esforço muito importante para pesquisadores e médicos. Este artigo revisa as mais recentes metodologias utilizadas no diagnóstico e tratamento de arritmias. Eles incluem a aplicação de cinco tipos diferentes de redes neurais artificiais treinadas por aprendizado de máquina e alimentadas por inteligência artificial: convolucional, recorrente, <i>feedforward</i> , função de base radial e rede neural modular. Algumas dessas metodologias são mescladas para aumentar a precisão e eficácia

## BIOMARCADORES VOCAIS

Segundo Amorim,<sup>27</sup> biomarcadores são parâmetros/características que auxiliam na confirmação diagnóstica de intoxicação aguda ou crônica, investigação do prognóstico e da eficiência do tratamento realizado. Eles especificam alguns fatores como patológicos ou normais, indicando, também, respostas aos fármacos. Há diferentes tipos de biomarcadores, como os histológicos, físicos, fisiológicos, anatômicos e vocais.

Segundo Fagherazzi et al.,<sup>28</sup> “a voz humana é um meio rico que serve como fonte primária de comunicação entre os indivíduos.” É uma das formas mais naturais e energeticamente eficientes de interagir uns com os outros. A voz, como conjuntos complexos de sons provenientes de nossas cordas vocais, contém várias informações e desempenha um papel fundamental para a interação social, permitindo-nos compartilhar *insights* sobre nossas emoções, medos, sentimentos e excitação, modulando seu tom ou ritmo.

A evolução da tecnologia de voz, análise de sinal de áudio e os métodos de processamento/compreensão da linguagem natural abriram caminho para inúmeras aplicações potenciais da voz, como a identificação de biomarcadores vocais para diagnóstico, classificação ou monitoramento remoto de pacientes, ou para aprimorar a prática clínica.<sup>29,30</sup>

Os biomarcadores vocais atuam de maneira rápida e não invasiva, tendo baixo custo para avaliar grandes populações, além de permitir acompanhamento de pessoas com alto risco para determinadas doenças. Pesquisadores da Universidade de São Paulo, envolvendo uma equipe e trabalho multidisciplinar, estão desenvolvendo o projeto Spira,<sup>31</sup> instrumento capaz de reconhecer variações na voz de pacientes com COVID-19.

Os pulmões desempenham um papel crítico na produção da voz, e esta pode ser afetada pelo líquido intersticial e edema pulmonar. Assim, é biologicamente plausível que a infecção por coronavírus 2 da síndrome respiratória aguda grave (SARS-CoV-2) possa ser detectada pela análise do sinal de voz. Um estudo piloto recente foi publicado sobre a investigação da associação entre análise de voz e infecção por SARS-CoV-2 em um registro clínico multicêntrico prospectivo.<sup>32</sup> Os resultados do estudo com 272 participantes foram promissores, demonstrando que a análise de voz está associada à infecção por SARS-CoV-2 e pode melhorar significativamente a classificação quando comparada a um classificador baseado em sintomas autorrelatados. Os usos clínicos possíveis para tal ferramenta são muitos e podem

incluir hospitais, shopping centers, aeroportos e centros de transporte público, para citar alguns. Outro uso clínico importante pode ser o apoio à decisão na classificação de candidatos a testes de PCR e se eles já precisam se auto-isolar ou estão apresentando sintomas relevantes.<sup>32</sup>

Além das soluções disponíveis no mercado de saúde suportadas pela IA, pesquisas de novas soluções estão em andamento em centros de pesquisa internacionais e universidades brasileiras. Atualmente, pesquisadores brasileiros estão desenvolvendo uma solução com biomarcadores vocais apoiados em IA para diagnóstico e acompanhamento de doenças. Uma equipe da Mayo Clinic identificou várias características vocais associadas a um histórico de doença arterial coronariana.<sup>33</sup>

Um outro estudo foi realizado por Maor et al.,<sup>34</sup> com pacientes com insuficiência cardíaca (ICC). A principal novidade desse estudo é que as características não invasivas do sinal de voz estão associadas a desfechos clínicos adversos, em pacientes com insuficiência cardíaca sintomática. A associação do biomarcador vocal com sobrevida ruim persistiu após ajuste para fatores de confusão relevantes e foi consistente em cada subconjunto de risco analisado, sugerindo uma associação independente. Assim, o estudo apoia o uso da análise do sinal de voz como biomarcador diagnóstico não invasivo para identificar pacientes com ICC de alto risco.<sup>34</sup> Este é o primeiro estudo a documentar uma relação entre um biomarcador vocal e resultados adversos entre pacientes com ICC, incluindo mortalidade e hospitalizações futuras. A análise do sinal vocal é um biomarcador não invasivo que pode auxiliar os profissionais de saúde na estratificação de risco individual do paciente.

Juntamente com outras ferramentas digitais de saúde, como visitas virtuais e monitoramento domiciliar, tem o potencial de auxiliar na prestação de cuidados de qualidade em comunidades rurais remotas. Isto trará benefícios tanto logísticos de monitoramento e diagnóstico precoce, bem como de custo-benefício associados ao acompanhamento desses pacientes.

Como qualquer campo impactado pela IA, as tecnologias de voz ou biomarcadores vocais precisam contar com algoritmos treinados em diversos conjuntos de dados, para limitar os preconceitos em relação a grupos sub-representados da população.

A Figura 3 sumariza as etapas recomendadas de avaliação de um biomarcador de voz, com base no framework V3.<sup>35</sup>

Nos últimos anos, com o uso generalizado de dispositivos vestíveis e *smartphones*, há um interesse crescente em uma



Figura 3. Etapas recomendadas de avaliação de um biomarcador de voz, com base no framework V3 Goldsack et al.<sup>35</sup>

análise remota de voz como uma ferramenta complementar de telemedicina não invasiva. Algoritmos de aprendizado de máquina ajudaram a identificar associação entre voz e vários estados de doença, incluindo doença arterial coronariana, hipertensão pulmonar e pacientes com insuficiência cardíaca congestiva em risco de readmissão e/ou morte. A voz é apenas um exemplo dos muitos biomarcadores digitais que estão surgindo nos últimos anos devido aos avanços em IA e algoritmos de aprendizado de máquina, juntamente com registros eletrônicos de *big data* de alta qualidade.

Torna-se claro que a voz será cada vez mais usada nos futuros sistemas de saúde: biomarcadores vocais rastrearão os principais parâmetros de saúde remotamente e serão usados para fenotipagem profunda de pacientes ou projetar ensaios inovadores, abrindo caminho para a medicina de precisão, enquanto as tecnologias de voz serão integradas à clínica prática para facilitar a vida de pacientes e profissionais de saúde. Para que o campo alcance a maturidade, precisamos passar de uma abordagem orientada para a tecnologia para uma abordagem mais orientada para a saúde, criando estudos e conjuntos de dados de alto valor, para fornecer evidências dos benefícios de tal abordagem.

## CONSIDERAÇÕES FINAIS

Em suma, à medida que a quantidade de dados relativos ao paciente aumenta e continuamos a incorporar novos fluxos

de dados biomédicos complexos à clínica, a IA se tornará essencial para a prática médica diária. A incorporação da IA na Medicina é um processo sem volta, que terá grande impacto na qualidade e segurança do atendimento ao paciente, porque os profissionais serão capazes de interpretar mais dados e em maior profundidade.<sup>36,37</sup> Para Quer et al.,<sup>36</sup> os algoritmos de ML, quando projetados, validados e implementados adequadamente, podem auxiliar na interpretação e sintetização de dados de cuidados de saúde provenientes de diferentes fontes, como se tivéssemos um subespecialista especializado a quem recorrer para cada paciente e cada situação clínica.

A comunidade médica deve estar qualificada para produzir, avaliar e conduzir a transformação digital, para que garanta melhores resultados na jornada dos pacientes e dos profissionais, que impacte positivamente na sustentabilidade do sistema e que viabilize melhor bem estar social. Assim, os profissionais da Saúde devem, portanto, assumir um papel de liderança na decisão de onde aplicar e como interpretar esses modelos.<sup>3,6</sup>

## CONFLITOS DE INTERESSE

Os autores declaram não possuir conflitos de interesse na realização deste trabalho.

## REFERÊNCIAS

1. PubMed. Bethesda: National Library of Medicine; 2022. [acesso 25 de janeiro de 2022]. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/?term=artificial+intelligence&filter=dates.2021%2F1%-2F1-2021%2F12%2F31&sort=date&size=200>
2. Valério Neto A, Berton L, Takahata AK. Ciência de dados e inteligência artificial na área da Saúde. São Paulo: Editora dos Editores. 2021;224.
3. Johnson KW, Torres Soto J, Glicksberg BS, Shameer K, Miotto R, Ali M, et al. Artificial intelligence in Cardiology. *J Am Coll Cardiol*. 2018;71(23):2668-79.
4. Morsh JA. Inteligência artificial na Medicina: 7 aplicações e benefícios. [acesso em 10 de janeiro de 2022]. Disponível em: <https://telemedicinamorsch.com.br/blog/inteligencia-artificial-na-medicina>
5. Lobo LC. Inteligência artificial e Medicina. *Rev Bras Educ Med*. 2017;41(2):185-93.
6. Kodera S, Akazawa H, Morita H, Komuro I. Prospects for cardiovascular medicine using artificial intelligence. *J Cardiol*. 2022;79(3):319-25.
7. A guide to enterprise AI: use cases and overcoming key barriers to adoption. *Research Pathfinder Report*. 2019.
8. Manlihot C, van den Eynde J, Kutty S, Ross HJ. A primer on the present state and future prospects for machine learning and artificial intelligence applications in Cardiology. *Can J Cardiol*. 2022;38(2):169-84.
9. Nakamura T, Sasano T. Artificial intelligence and cardiology: current status and perspective. *J Cardiol*. 2022;79(3):326-33.
10. Souza Filho EM, Fernandes FA, Soares CLA, Seixas FL, Santos AASMDD, Gismondi RA, et al. Artificial intelligence in Cardiology: concepts, tools and challenges - "the horse is the one who runs, you must be the jockey". *Arq Bras Cardiol*. 2020;114(4):718-25.
11. Dorado-Díaz PI, Sampedro-Gómez J, Vicente-Palacios V, Sánchez PL. Applications of artificial intelligence in Cardiology. The future is already here. *Rev Esp Cardiol (Engl Ed)*. 2019;72(12):1065-75.
12. Kriegeskorte N, Golan T. Neural network models and deep learning. *Curr Biol*. 2019;29(7):R231-36.
13. Renganathan V. Overview of artificial neural network models in the biomedical domain. *Bratisl Lek Listy*. 2019;120(7):536-40.
14. Fei Y, Li WQ. Improve artificial neural network for medical analysis, diagnosis and prediction. *J Crit Care*. 2017;40:293.
15. Cypko M, Emmert MY, Falk V, Meyer A. [Artificial intelligence in cardiac surgery]. *Chirurg*. 2020;91(3):235-9.
16. Fu W, Breininger K, Wurfl T, Ravikumar N, Schaffert R, Maier A. Frangi-Net: a neural network approach to vessel segmentation. In: *Bildverarbeitung für die Medizin*. Heidelberg: Springer Vieweg. 2018;341-6.
17. Scotti L, Ishiki H, Mendonça Júnior FJB, Silva MS, Scotti MT. Artificial neural network methods applied to drug discovery for neglected diseases. *Comb Chem High Throughput Screen*. 2015;18(8):819-29.
18. Krittanawong C, Johnson KW, Rosenson RS, Wang Z, Aydar M, Baber U, et al. Deep learning for cardiovascular medicine: a practical primer. *Eur Heart J*. 2019;40(25):2058-73.
19. Petch J, Di S, Nelson W. Opening the black box: the promise and limitations of explainable machine learning in Cardiology. *Can J Cardiol*. 2021;S0828-282X(21)00703-0.
20. Bos JM, Attia ZI, Albert DE, Noseworthy PA, Friedman PA, Ackerman MJ. Use of artificial intelligence and deep neural networks in evaluation of patients with electrocardiographically concealed long QT syndrome from the surface 12-lead electrocardiogram. *JAMA Cardiol*. 2021;6(5):532-8.
21. Feeny AK, Chung MK, Madabhushi A, Attia ZI, Cikes M, Firouznia M, et al. Artificial intelligence and machine learning in arrhythmias and cardiac electrophysiology. *Circ Arrhythm Electrophysiol*. 2020;13(8):e007952.
22. López-Martínez F, Núñez-Valdez ER, Crespo RG, García-Díaz V. An artificial neural network approach for predicting hypertension using NHANES data. *Sci Rep*. 2020;10(1):10620.
23. Andersson P, Johnsson J, Björnsson O, Cronberg T, Hassager C, Zetterberg H, et al. Predicting neurological outcome after

- out-of-hospital cardiac arrest with cumulative information; development and internal validation of an artificial neural network algorithm. *Crit Care*. 2021;25(1):83.
24. Jang DH, Kim J, Jo YH, Lee JH, Hwang JE, Park SM, et al. Developing neural network models for early detection of cardiac arrest in emergency department. *Am J Emerg Med*. 2020;38(1):43-9.
25. Mohammad MA, Olesen KKW, Koul S, Gale CP, Rylance R, Jernberg T, et al. Development and validation of an artificial neural network algorithm to predict mortality and admission to hospital for heart failure after myocardial infarction: a nationwide population-based study. *Lancet Digit Health*. 2022;4(1):e37-e45.
26. Abbas M, Alqahtani M, Al-Gahtani SF, Algahtani A, Kessentini A, Loukil H, et al. Contribution of neural networks in the diagnosis and treatment of cardiac arrhythmia. *Discov Med*. 2020;30(159):27-38.
27. Amorim LCA. Os biomarcadores e sua aplicação na avaliação da exposição aos agentes químicos ambientais. *Rev Bras Epidemiol*. 2003;6(2):158-70.
28. Fagherazzi G, Fischer A, Ismael M, Despotovic V. Voice for Health: the use of vocal biomarkers from research to clinical practice. *Digit Biomark*. 2021;5(1):78-88.
29. Robin J, Harrison JE, Kaufman LD, Rudzicz F, Simpson W, Yancheva M. Evaluation of speech-based digital biomarkers: review and recommendations. *Digit Biomark*. 2020;4(3):99-108.
30. Sara JDS, Maor E, Borlaug B, Lewis BR, Orbelo D, Lerman LO, et al. Non-invasive vocal biomarker is associated with pulmonary hypertension. *PLoS One*. 2020;15(4):e0231441.
31. Finger M. Estudo SPIRA: Sistema de detecção precoce de insuficiência respiratória por meio de análise de áudio. Processo 2020/06443-5. Acesso em 10 de janeiro de 2022. Disponível em: <https://bv.fapesp.br/pt/auxilios/106459/estudo-spira-sistema-de-deteccao-precoce-de-insuficiencia-respiratoria-por-meio-de-analise-de-audio/>
32. Maor E, Tsur N, Barkai G, Meister I, Makmel S, Friedman E, et al. Noninvasive vocal biomarker is associated with severe acute respiratory syndrome coronavirus 2 infection. *Mayo Clin Proc Innov Qual Outcomes*. 2021;5(3):654-62.
33. Maor E, Sara JD, Orbelo DM, Lerman LO, Levanon Y, Lerman A. Voice signal characteristics are independently associated with coronary artery disease. *Mayo Clin Proc*. 2018;93(7):840-7.
34. Maor E, Perry D, Mevorach D, Taiblum N, Luz Y, Mazin I, et al. Vocal biomarker is associated with hospitalization and mortality among heart failure patients. *J Am Heart Assoc*. 2020;9(7):e013359.
35. Goldsack JC, Coravos A, Bakker JP, Bent B, Dowling AV, Fitzer-Attas C, et al. Verification, analytical validation, and clinical validation (V3): the foundation of determining fit-for-purpose for Biometric Monitoring Technologies (BioMeTs). *NPJ Digit Med*. 2020;3:55.
36. Quer G, Arnaout R, Henne M, Arnaout R. Machine learning and the future of cardiovascular care: JACC state-of-the-art review. *J Am Coll Cardiol*. 2021;77(3):300-13.
37. Krittanawong C, Zhang H, Wang Z, Aydar M, Kitai T. Artificial intelligence in precision cardiovascular medicine. *J Am Coll Cardiol*. 2017;69(21):2657-64.



# INTELIGÊNCIA ARTIFICIAL PARA MONITORAMENTO REMOTO DO PACIENTE

## ARTIFICIAL INTELLIGENCE FOR REMOTE PATIENT MONITORING



Clique para acessar  
o Podcast

Roberto Vieira Botelho<sup>1</sup>  
Sameer Mehta<sup>2</sup>  
Fausto Feres<sup>2</sup>  
Francisco Fernández<sup>3</sup>  
Wladimir Rezende<sup>4</sup>

1. Fundação Adib Jatene. São Paulo, SP, Brasil.
2. Lumen Foundation, Division of Telemedicine & Artificial Intelligence, Miami, FL, USA.
3. Instituto Dante Pazzanese de Cardiologia. São Paulo, SP, Brasil.
4. Cardionomous, Chile.
5. UMC Tecnologia S.A., Bitboundaire.

Correspondência:  
Roberto Vieira Botelho.  
robertotelho@mac.com

### RESUMO

O monitoramento remoto do paciente (MRP) expressa a coleta e a transmissão de dados de saúde do paciente de fora do sistema de saúde para servidores, por meio de dispositivos. Esses servidores podem estar muito próximos do paciente (computação em borda), podem estar em nuvem ou em campo intermediário (computação em névoa). A coleta de sinais biológicos pode ser dividida em quatro categorias: equipamentos médicos estacionários, dispositivos implantáveis, dispositivos usáveis, prescritos por médicos e dispositivos monitores portáteis em geral. A Internet das Coisas Médicas (ICM) apresenta oportunidade de coletar grande volume de dados do paciente e de seu ambiente (poluição, temperatura, umidade, altitude, etc.). As quatro categorias de coleta de sinais biológicos podem transmitir esses dados continuamente ou ser desencadeados por eventos e pelo usuário. Essa transmissão pode ser direcionada para servidores próximos dos pacientes, sofrer encriptação, classificação, compressão e predição. A partir daí, pode ser encaminhada a interfaces (névoa/fog) que antecedem os computadores em nuvem. Neste nível intermediário, pode haver processamento computacional com menor latência, antes de ser encaminhada à nuvem. O emprego de ICM exige arquitetura adequada, com cuidados sobre a latência, assim como a segurança, acessibilidade, interoperabilidade e privacidade. Camadas intermediárias podem enriquecer esse ecossistema e transformar o modelo de assistência em saúde. Entre essas tecnologias, destaca-se o Blockchain, que provê privacidade e segurança, além de criar melhor gestão das transações de dados em saúde.

As plataformas de telecomunicações têm transformado esse cenário, especialmente através do 5G, que oferecem quatro elementos especiais: alta velocidade com capilaridade, confiabilidade com baixa latência, comunicação maciça de máquinas ou dispositivos médicos e aproveitamento de energia para recarga de dispositivos. Parte integrante do MRP é o processamento analítico dos dados, especialmente potencializados por Inteligência Artificial (IA). Uma das maiores contribuições da IA no MRP é a diversidade de sinais utilizáveis. Os computadores analisam eventos repetitivos e derivam algoritmos ininteligíveis à cognição humana. A IA, alimentada por enorme volume de dados provenientes dos pacientes e de seus ambientes, promoverá revolução sem precedentes na saúde. A explosão de dados proverá diagnósticos e tratamentos melhor informados, mais precisos e personalizados, de menor custo e maior eficiência.

**Descritores:** Inteligência Artificial; Telemonitoramento; Telemedicina.

### ABSTRACT

*Remote patient monitoring (RPM) is the collection and communication of patients' healthcare data from outside the healthcare system to servers through devices. These servers can be very close to the patient (edge computing), in the cloud, or in the intermediate space (fog computing). The collection of biological signals can be divided into four categories: stationary medical equipment, implantable devices, wearable devices prescribed by physicians, and portable monitoring devices in general. The Internet of Medical Things (IoMT) facilitates the collection of large volumes of data from patients and their environment (pollution, temperature, humidity, altitude, etc.). The four categories for biological signal collection can transmit this data continuously or when triggered by events and by the user. This transmission can be directed to edge servers close to patients and undergo encryption, classification, compression, and prediction. The data can then be forwarded to interfaces (fog) that precede the cloud computers. At this intermediate level, computational processing with lower latency can happen before sending the data to the cloud. The use of IoMT requires an adequate architecture that takes latency, as well as*

*security, accessibility, interoperability, and privacy into account. Intermediate layers can enrich this ecosystem and transform the healthcare model. Blockchain stands out among these technologies. It provides privacy, security, and better management of healthcare data transactions. Telecommunication platforms have changed this scenario, especially through 5G technology, which offers four special elements: high speed with capillarity, reliability with low latency, massive communication between machines or medical devices, and use of energy to recharge devices. The analytical processing of data is an integral component of RPM, especially when enhanced by artificial intelligence (AI). One of the biggest contributions of AI to RPM is the diversity of usable signals. Computers analyze repetitive events and derive algorithms unintelligible to human cognition. Powered by massive amounts of data from patients and their environments, AI will drive an unprecedented revolution in healthcare. The data explosion will provide better-informed, more accurate, and customized diagnoses and treatments at lower costs and with better efficiency.*

**Keywords:** Artificial Intelligence; Telemonitoring; Telemedicine.

## INTRODUÇÃO

Atualmente, as doenças crônicas como asma, diabetes, afecções cardiovasculares e doenças mentais são as principais causas de morbidade e mortalidade em nosso meio. O número de pessoas vivendo com múltiplas doenças crônicas é crescente ante ao envelhecimento populacional e a progressiva adoção de hábitos de vida pouco saudáveis.<sup>1,2</sup> Assim, há crescente interesse e necessidade de monitoramento remoto de pacientes para melhor controle dessas condições, além de sua prevenção. Também merece destaque a possibilidade de empoderamento dos pacientes para melhor gestão de suas próprias saúdes, apoiados por sistemas inteligentes. O MRP é um campo emergente do sistema de saúde que busca gestão da saúde/doença utilizando tecnologia da informação e telecomunicações. Utiliza diferentes ferramentas para coletar dados biológicos a partir do ambiente domiciliar ou mesmo do trabalho das pessoas/pacientes e os transmite para profissionais de saúde a fim de avaliação e recomendações.<sup>3</sup> O número de dispositivos para MRP cresceu de 325 milhões em 2016 para 929 milhões em 2021.<sup>4</sup>

Uma revisão sistemática sobre as experiências e expectativas sobre MRP dos pacientes com doenças crônicas mostrou respostas que merecem a atenção dos profissionais de saúde: 62% dos pacientes preferem médicos que utilizem seus dados provenientes de MRP. Cerca de 78% dos pacientes estão dispostos a fornecer aos médicos acesso aos dados de seus dispositivos de monitorização. Até 67% dos usuários aceitarão utilizar MRP fornecida por sua seguradora de saúde, desde que tenham prêmios em reduções de mensalidades.<sup>5</sup> Ainda sob a perspectiva dos usuários, as principais barreiras à adoção de MRP são: a estética dos devices, sua usabilidade/ergonomia, seu custo e a capacidade do sistema em prover resposta em tempo adequado.<sup>6</sup>

O avanço exponencial da velocidade de processamento computacional, a progressiva miniaturização, a custos cada vez menores, aliados ao também fenomenal progresso dos meios de comunicação, criam ambiente fomentador de camadas progressivas de soluções. Desde 1965, Gordon Moore, co-fundador da Intel, previu que o número de transistores incorporados em um chip iria dobrar a cada dois anos. Essa previsão foi batizada de "lei de Moore" e tem sido observada até a atualidade.<sup>7</sup> Recentemente, a publicação da supremacia quântica, em que um processador supercondutor

programável, o Sycamore, processou em 200 segundos tarefa que o estado da arte dos supercomputadores atuais levaria 10 mil anos.<sup>8</sup> O limite de Moore parece estar a caminho da superação. No início, a MRP se limitava à transmissão de ondas, como eletrocardiograma, à distância. Atualmente, a miniaturização de sensores já nos apresenta a realidade dos nano-sensores, capazes de "sentir" variações plasmáticas de eletrólitos a partir de chips sub-cutâneos.<sup>9</sup>

Por outro lado, há respeitável desafio para a implementação das tecnologias disponíveis no ambiente da saúde, como a inter-operabilidade, a privacidade, a segurança, o estabelecimento de padrões tecnológicos e protocolos de tele-comunicação, o acompanhamento regulatório, especialmente das tecnologias que ocultam seus próprios algoritmos, as análises de custo/efetividade, entre outros.<sup>10, 11</sup>

Aplicar inteligência artificial (IA) aos dados coletados pela MRP oferece salto adicional à saúde. Algumas aplicações já se mostraram superiores aos médicos quanto à capacidade diagnóstica. Ainda assim, estudos de IA precisam demonstrar alguns fundamentos: imparcialidade (dados imputados e o modelo devem ser livres de vieses), robustez (os sistemas devem ser seguros), explicabilidade (as decisões tomadas pelos modelos precisam ser entendidas pelos usuários) e transparência (informações sobre seu desenvolvimento, aplicação e manutenção).<sup>12</sup> Esses elementos ajudam o engajamento dos profissionais de saúde, ao entenderem que serão ferramentas complementares e dependentes da inteligência humana.<sup>13</sup> Os profissionais sem IA serão substituídos. Mas, por outros profissionais que utilizem IA.

## COMPONENTES DO MONITORAMENTO REMOTO DO PACIENTE

Um sistema de MRP consiste, basicamente de três componentes fundamentais: tecnologia para aquisição de dados, rede de transmissão e plataforma de processamento e análise.<sup>3</sup> Cada componente pode se diferenciar desde tecnologias simples às mais sofisticadas, oferecendo capacidade exponencial de ampliação do alcance e resolutibilidade.

Quanto à aquisição, pode se dar através de sensores ou dispositivos, como telefones celulares, com sensores embarcados e capacidade de transmissão sem fio e pode ser dividida em quatro categorias: equipamentos médicos estacionários, dispositivos implantáveis, dispositivos usáveis,

prescritos por médicos e dispositivos monitores portáteis em geral.<sup>3</sup> A base da aquisição dos dados está nos sensores. Estes experimentam evolução que acompanha a previsão de Moore. Além de redução de tamanho, passam a hospedar capacidade computacional em si mesmos e, mais relevante ainda, carregam sua própria comunicação.

## INTERNET DAS COISAS MÉDICAS E MONITORAMENTO REMOTO

Internet das coisas (IdC) se refere a um conjunto conectado de qualquer coisa, a qualquer momento, em qualquer lugar, para qualquer serviço através de qualquer rede (de telecomunicações).<sup>14</sup>

A idéia de conectar pessoas a objetos físicos através da IdC, mais especificamente, internet das coisas médicas (IdCM) ou das nano-coisas médicas (IdNCM), pode trazer impressionantes incrementos na qualidade de vida. Para isso, é preciso transformar esses objetos em suas versões “inteligentes”. De fato, esses objetos passam a capturar, compartilhar e comunicar dados das pessoas com servidores, onde esses dados possam ser analisados para entregar serviços inteligentes. Entre os objetos que podem se tornar inteligentes estão os carros, casas, eletrodomésticos, relógios, anéis, óculos, camas de hospital, dispensadores de comprimidos, etc.<sup>15</sup>

O mercado mundial de IdCM (somente IdC para saúde) pode chegar a US\$534 bilhões em 2025.<sup>16</sup>

A arquitetura básica da IdC consiste de cinco camadas: percepção, rede, Middleware (pacote de software que atua na interface entre os componentes do ecossistema de IdC), aplicação e gestão. Essa arquitetura permite captura e coleta de dados de pessoas, assim como de sua ecologia (umidade do ar, temperatura ambiente, poluição, etc).<sup>16</sup> Um exemplo intrigante de sensores ambientais é um modelo de lâmpada capaz de monitorar a frequência cardíaca, temperatura corporal e o sono.<sup>17</sup> Sua versão wi-fi se comunica com as plataformas inteligentes Alexa, Google e Samsung. Já sua versão Bluetooth se comunica com Alexa, por enquanto. A consequência natural desse monitoramento contínuo de toda fonte de dados possíveis é a maciça geração e sobrecarga da transmissão, do armazenamento e do processamento. Por isso, é fundamental que se estruture rede hierárquica de comunicação, conforme descreveremos adiante.<sup>14</sup> Há desafios relevantes quanto à segurança, especialmente devido à diversidade dos sensores, que não são objeto de uma única estratégia, como criptografia. Alguns sensores são ativos e contêm bateria, como os relógios. Outros, são passivos e sem baterias, como RFID (identificação por radiofrequência). Da mesma forma, os protocolos de comunicação podem consumir muita energia, como wifi, ou não, como bluetooth de baixa energia. A estratégia de segurança, que envolve autenticação (cada dispositivo envolvido na comunicação precisa ser identificável), confidencialidade (somente pessoas autorizadas têm acesso aos dados) e integridade (os dados não podem ser modificados durante seu trajeto), precisa estar nas duas pontas, do sensor e do centro de processamento.<sup>15-17</sup>

Outro desafio é a privacidade. Os usuários precisam saber o destino de seus dados e ter segurança que não serão explorados para fins não autorizados, o que pode impactar muito na aceitação da tecnologia. Mais adiante, discutiremos soluções como *blockchain*.

O ambiente de IdC precisa lidar com a heterogeneidade dos fabricantes, protocolos de comunicação e inter-operabilidade. É fundamental a padronização para que a oportunidade seja amplamente aproveitada em saúde.

## COMPUTAÇÃO EM NUVEM, EM “FOG” E COMPUTAÇÃO DE BORDA

À medida que a necessidade de “Data Centers” aumentava, devido ao aumento de processamento em lotes e aplicações remotas, nasceu a interessante alternativa da computação em nuvem, que oferece estrutura compartilhada de servidores remotos com todos os requerimentos de um Data Center. Esse conceito baixou custos, retirou complexidade das operações e ampliou exponencialmente a capacidade de hospedagem e processamento de dados. O amplo emprego de IdCM, coletando dados dos pacientes e de seus ambientes, promoverá maciça produção de dados a serem transportados desde a coleta até o processamento. Esse volume de dados é um desafio para as arquiteturas de MRP, não só pela sobrecarga de dados, mas, pelo consumo de energia.<sup>18</sup> Um exemplo são as tecnologias que coletam dados sem contato com o paciente, como câmeras que capturam imagens faciais continuamente e, através de computação visual conseguem detectar arritmias cardíacas.<sup>19</sup> O volume de dados gerados por uma única câmera chega a 40 GB por dia, sendo inviável a arquitetura de nuvem para esta aplicação. A necessidade de segurança, privacidade e integridade dos dados requer especial infra-estrutura para que a fluência não seja afetada, especialmente em situações que requeiram baixa ou nenhuma latência, como exemplo, o controle automático de injeção de insulina a partir de sensores inteligentes de glicemia.

Essas operações que exigem baixa ou nenhuma latência necessitam estrutura intermediária (nodes) nas proximidades da captura dos dados. Essa estrutura intermediária coleta, comprime e processa dados antes de enviá-los a uma nuvem intermediária (fog) que esteja próxima do paciente. Ali pode haver análise dos dados, seja por profissionais de saúde ou por IA, retornando orientação ao paciente.<sup>20</sup>

O emprego eficiente das diferentes alternativas de IdCM exigirá arquiteturas apropriadas para cada aplicação. O conceito de computação de borda e nuvens intermediárias pode viabilizar o pleno aproveitamento do alto volume de dados submetidos a diferentes modelos de IA.<sup>20</sup>

Uma das mais significativas transformações a propiciar essa arquitetura é a tecnologia 5G.<sup>21</sup> A Tabela 1 apresenta os principais diferenciais dessa tecnologia, em comparação com as anteriores. Destacam-se a baixa latência, a velocidade, baixo consumo de energia e a maior capacidade de conectar múltiplos dispositivos. Uma revolução para a integração com os diferentes dispositivos médicos remotos e IdC é a capacidade de aproveitar e transportar energia, recarregando estes dispositivos ou dispensando baterias.<sup>22</sup>

A consequência final dessa arquitetura e os múltiplos dispositivos conectados às pessoas ou ao ambiente é a maciça geração de dados. O cuidado com a jornada do dado, além dos aspectos de segurança, privacidade e confidencialidade, representam a maior transformação desse ecossistema, tanto em indicadores clínicos, como em monetização. Por isso, a seguir, apresentaremos a sugestão de Blockchain para segurança, privacidade e monetização por contratos inteligentes.

**Tabela 1.** Principais diferenciais das redes 5G, em comparação com 4G e Wi-Fi.

Característica	Descrição	Wi-Fi	4G	5G
Latência	Retardo entre envio e recepção do dado. Quanto menor, mais “tempo real”	20 milissegundos	30 a 50 milissegundos	1 a 10 milissegundos
Velocidade	Velocidade esperada por usuário/dispositivo	1 Gbps	20 a 50 Mbps	1 Gbps
Densidade de Conexão	Número de devices conectados por unidade de área	8 por parte	12 por parte	100 por parte
Energia	Consumo comparativo	Médio	Alto	Médio

## BLOCKCHAIN E MONITORAMENTO REMOTO – DA SEGURANÇA AOS CONTRATOS INTELIGENTES

No artigo *Data is a Toxic Asset*<sup>23</sup> Bruce Schneier faz um brilhante paralelo entre o armazenamento de grandes volumes de dados e os terríveis riscos envolvidos em um eventual vazamento das informações coletadas. Utilizando os fundamentos apresentados por Schneier, podemos realizar um paralelo entre armazenamento de dados e a indústria petrolífera: o petróleo armazenado nos bolsões profundos da terra é um ativo tóxico. Quando ocorrem vazamentos durante qualquer uma das etapas de sua cadeia logística ou de produção, as consequências são desastrosas para o meio ambiente. Dados vazados são tóxicos, pois trazem consequências também desastrosas para indivíduos, organizações e todos aqueles que direta ou indiretamente participam de sua cadeia logística e de produção.

Nos meios de armazenamento e compartilhamento de dados tradicionais<sup>24</sup> faz-se necessária uma entidade centralizadora, controladora e certificadora que garante, através de sua reputação, a segurança e confiabilidade das informações. Infelizmente, mesmo grandes corporações, que investem centenas de milhões de dólares em segurança, são vítimas de vazamentos catastróficos de dados. Isso nos mostra que o modelo tradicional de armazenamento e compartilhamento de informações não é adequado aos desafios relatados nos capítulos anteriores.

Incrivelmente, uma tecnologia criada em 1494 pelo padre Luca Pacioli<sup>25</sup> trouxe a chave para resolver esse gigantesco problema. Pacioli criou o livro razão ou “ledger”, uma ferramenta contábil para o monitoramento de entradas e saídas. No encadeamento lógico do livro razão, entradas (créditos) e saídas (débitos) devem estar concatenadas e arranjadas em uma estrutura linear que permite que os dados sejam adequadamente controlados e auditados. Mas qualquer pessoa com acesso ao livro razão pode ver os dados ali contidos e isso é um componente indesejável para a segurança dos dados. Foi então que outra tecnologia que nasceu na antiguidade foi utilizada para resolver essa limitação, a criptografia. Através da criptografia mesmo que alguém tenha acesso a informações vazadas não poderá visualizar o seu conteúdo. Tendo como base essas duas tecnologias, o criptógrafo David Chaum<sup>26</sup> fundou em 1983 a empresa DigiCash e seu produto E-cash que pretendia criar uma moeda eletrônica com total proteção das transações através da anonimização dos dados sensíveis envolvidos nas operações de crédito e débito. Os conceitos criados por Chaum foram então utilizados e aprimorados por Nick Szabo,<sup>27</sup> um dos sócios da DigiCash, que realizou uma pesquisa em contratos digitais e moedas

digitais que culminaram com a criação de uma moeda digital chamada Bit Gold. A tecnologia da DigiCash estava muito à frente de seu tempo e a empresa foi fechada, mas a semente plantada por Chaum e Szabo veio a florescer em 2008, quando Satoshi Nakamoto (pseudônimo de uma pessoa até o momento desconhecida), publica o artigo “Bitcoin: A Peer-to-Peer Electronic Cash System.”<sup>28</sup> No artigo, Nakamoto propõe uma solução alternativa às transações que existem no mundo atual, onde essas dependem quase totalmente de instituições centralizadoras que funcionem como garantidoras das transações. Ele aponta que a centralização aumenta os riscos, pois caso um atacante assuma o controle da instituição comprometerá totalmente suas transações, e aumenta os custos das transações e não tem segurança garantida, já que uma transação pode ser revertida mesmo após a realização de uma operação e isso faz com que as partes envolvidas desconfiem umas das outras, o que aumenta os gastos com atividades de acreditação e anti-fraude. Por isso, segundo Nakamoto, existe uma necessidade latente da realização de transações entre duas ou mais partes de maneira descentralizada, com a impossibilidade de serem revertidas e com rotinas transacionais que protejam adequadamente os envolvidos. Foi então proposto o *Blockchain* como uma maneira elegante de resolver esse problema.<sup>28</sup>

Se fossemos explicar o que é *Blockchain* para uma criança diríamos que é como brincar de Lego, mas todos os seus amigos devem concordar com você quando for movimentar uma peça. Isso significa que a segurança das transações é garantida pela soma de todos os elos da corrente e não mais pela resistência do seu elo mais fraco. A descentralização é então transformada em uma imensa camada a grande proteção. Para um atacante, invadir um único sistema centralizado é uma tarefa factível, que exige apenas paciência, tempo e recursos, mas invadir um sistema descentralizado formado por milhares de pares (peers) é tarefa praticamente impossível com os recursos computacionais disponíveis.

Portanto, o armazenamento de dados em uma nuvem descentralizada garante a segurança, inviolabilidade, auditoria, transparência e consistência das informações e isso é o que justamente buscamos para garantir que os dados dos pacientes estejam adequadamente armazenados e sejam acessados apenas por indivíduos e organizações autorizados.

É importante entender que *Blockchain* é apenas um tipo de tecnologia de livro razão distribuído (*Distributed Ledger Technology – DLT*).<sup>27</sup> Usualmente os meios de comunicação tratam todos os DLTs como *Blockchain*, mas isso é uma forma equivocada e simplista de tratar a questão.<sup>29</sup> *Blockchain* foi o tipo de DLT criado para que a criptomoeda Bitcoin pudesse surgir e prosperar, ou seja, tecnologia *Blockchain* é apenas um tipo de DLT.

A tecnologia dos “DLTs” evoluiu assombrosamente nos últimos anos e grandes entraves para a sua adoção no armazenamento e compartilhamento de dados foram removidos, o maior deles era o custo computacional e energético necessário envolvidos em sua operação. Atualmente, tecnologias de oráculos descentralizados (*Decentralized Oracles*), como a disponibilizada pela Chainlink, permitem a interconexão de DLTs com bases de dados node, fog ou cloud com custo computacional adequado para essa operação.<sup>30</sup>

Essa estrutura DLT combinada com a anonimização dos dados dos pacientes e a utilização de contratos inteligentes híbridos permitirá que essas informações sejam monetizadas com total controle e segurança, criando a ponte para a remoção da toxicidade dos dados e permitindo o nascimento de uma nova e poderosa fonte de informações para dados clínicos, dados de estudos, dados demográficos, dados transacionais, dados de performance, dados epidemiológicos, dados de mercado, dados genômicos, dados de mundo real (dispositivos, vestíveis e aplicativos), prescrições, dispensações entre outros.

Em recente artigo de revisão, Pranav Ratta discute as principais vantagens de *Blockchain* para viabilizar IdM, especialmente, descentralização, inviolabilidade, segurança, privacidade e transparência.<sup>31</sup>

A conjugação de todos esses elementos criará uma indústria que atenderá as legislações vigentes e criará as bases para uma gigantesca revolução na medicina.

## INTELIGÊNCIA ARTIFICIAL E O PENSAMENTO ANTROPOMÓRFICO REVERSO

Inteligência artificial, iniciada na primeira metade do século 20, é definida como a utilização de computadores para modelar comportamento inteligente, com a mínima (ou nenhuma) interferência humana. Um de seus mais relevantes aspectos foi discutido por Eric Topol em seu livro *Deep Medicine*, o pensamento antropomórfico reverso.<sup>32</sup> Os homens são condicionados a esperar dos computadores a lógica de seus próprios pensamentos. O entendimento de que aos computadores bastam os eventos repetitivos para que criem algoritmos a partir de grandes volumes de dados é um grande avanço. Tivemos essa experiência quando um engenheiro de nosso grupo sugeriu treinar máquinas para detecção de infarto a partir de uma derivação de eletrocardiograma.<sup>33</sup> O nosso modelo mental, como médicos, é hipotético-dedutivo. Muitos pesquisadores concordam que os processos intuitivos são as principais fontes geradoras de hipóteses diagnósticas pelos médicos.<sup>34</sup> Por outro lado, o aprendizado de máquina depende do desenvolvimento de um algoritmo que “aprenda” padrões relevantes de um conjunto de dados (dados de aprendizagem) para, então, fazer previsões sobre outro conjunto desconhecido de dados. Para que o aprendizado ocorra, os dados de aprendizagem precisam ser classificados conforme sua associação com a solução. Por isso, são chamados valor de referência. Essa é uma das etapas mais desafiadoras da IA, pois se há mínimos erros na classificação de bilhões de dados, o produto pode ser desastroso.<sup>34</sup>

Cardiologistas detectam a hipótese de um infarto através

do eletrocardiograma, avaliando desvios do segmento ST a partir de diferentes derivações. Como máquinas, a partir de uma amostra de 8511 ECGs da base de dados do programa LATIN (Latin America Telemedicine Infarct Network) treinamos modelo de aprendizado profundo de máquina (camadas encadeadas de forma hierárquica) para o diagnóstico de infarto com supra de ST (STEMI) a partir de cada derivação do ECG. Obtivemos acurácia de 90,5% para a derivação V2.<sup>33</sup> A derivação mais utilizada em relógios inteligentes, como o *Apple Watch*, é D1,<sup>35</sup> para a qual obtivemos área sob a curva ROC de 0,85.<sup>33</sup> (Figura 1)

Entretanto, pode-se aplicar o relógio em outras regiões, além do pulso, em busca de outras derivações, como D2, D3 e precordiais modificadas.<sup>35</sup>

A seguir, partimos para a validação do modelo na prática clínica (Roberto Botelho). Na Figura 2 observamos os achados do primeiro paciente avaliado. No sentido anti-horário, o eletrocardiograma de 12 derivações, o registro do ECG de uma derivação através do *Apple Watch* e a resposta do algoritmo (69% de chance de STEMI). Na Figura 3, observamos a angiografia coronária antes e após angioplastia primária deste primeiro paciente.

Na Figura 4, o ECG de uma paciente encaminhada com desconforto torácico. As alterações de ST e T na parede

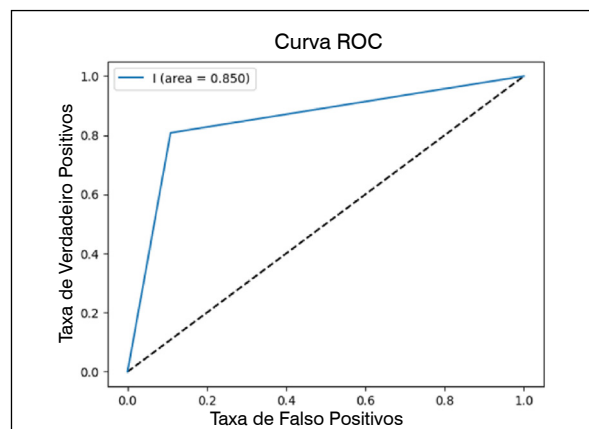


Figura 1. Área sob a Curva (Curva ROC) calculada a partir da sensibilidade e especificidade do algoritmo para detecção de infarto utilizando-se a derivação D1 do ECG.

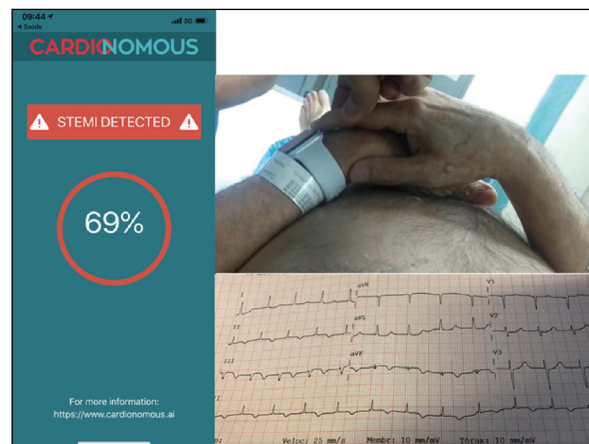



Figura 2. No sentido anti-horário, o eletrocardiograma de 12 derivações, o registro do ECG de uma derivação através do *Apple Watch* e a resposta do algoritmo (69% de chance de STEMI).


anterior, ante ao quadro clínico, faziam suspeitar-se de infarto anterior. A resposta do algoritmo: 77% de chance de não ser infarto, resposta confirmada pela coronariografia e ventriculografia. (Figura 5)

A figura 6 mostra um caso típico de ECG diagnóstico de supradesnivelamento de ST em parede anterior, algoritmo sugerindo 82% de chance de infarto, na fase hiper-agudo do evento.

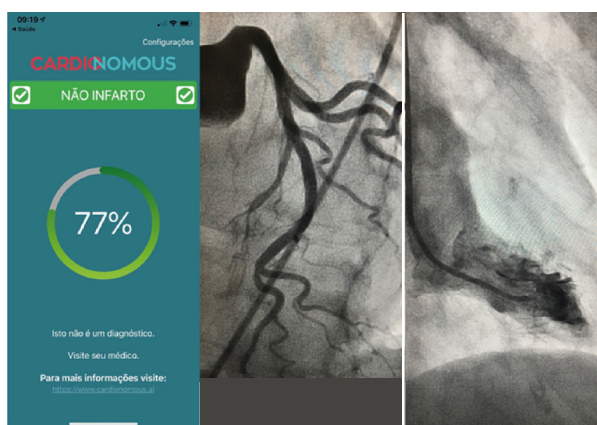
Podemos observar nesses exemplos a capacidade da máquina “pensar” diferente, a partir de variáveis desconhecidas pelo homem. Sob o mesmo princípio, há modelos que aplicam reconhecimento de voz para detecção de depressão.<sup>36</sup> Essas linhas de pesquisa convidam à busca de outras fontes de escores a partir de grandes lagos de dados, gerados a partir de MRP.



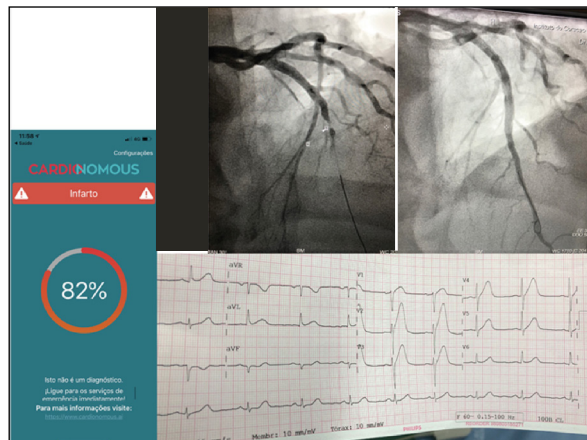
**Figura 3.** Imagem da coronária direita ocluída (à esquerda) e após angioplastia primária (à direita).



**Figura 4.** ECG de 12 derivações de uma paciente com desconforto torácico.



**Figura 5.** Resposta do algoritmo com 77% de chance de não ser infarto. À direita, a foto da angiografia da coronária esquerda e ventriculografia em systole.



**Figura 6.** No sentido anti-horário, o ECG, foto da angiografia pré e pós angioplastia primária e a resposta do algoritmo, sugerindo 82% de chance de Infarto.

Para a digestão desse enorme lago de dados, especialmente informações relevantes que não estejam estruturadas (por exemplo, texto livre), um programa computacional utilizando IA pode ler esses dados e guardar para uso posterior. Esses algoritmos são baseados em processamento de linguagem natural (PLN) e podem extrair significado, sentimento, ou mesmo a intenção de um texto escrito por humano.<sup>37</sup> Entre as aplicações de PLN em MRP, destacamos:

Gravação de notas por pacientes, extraídas de consultas médicas, ou por médicos, durante procedimentos cirúrgicos.

Chatbots (programas que tentam simular um humano na conversa com as pessoas) conseguem interagir com pacientes e auxiliar na condução de diagnósticos e orientações terapêuticas.

Há aplicações de “Entendimento” de Linguagem Natural (ELN) que se conectam a bancos de dados e “entendem” a anamnese, correlacionam com histórico do prontuário e recomendam intervenções apropriadas, baseadas em diretrizes, individualizadas para a realidade do paciente.<sup>38</sup>

O sistema de saúde do Reino Unido tem integrado o Babylon health para um grupo de usuários. Através de avançados algoritmos de IA, os pacientes podem interagir com *Chatbots*, avaliar seus sintomas, receber recomendações, inclusive prescrições, ou, automaticamente, agendar e ativar videoconsultas com médicos triados conforme a especialidade.<sup>39</sup>

Da mesma forma, é muito fértil a interação dos dados biológicos com os ambientais, oportunidade nunca explorada de maneira síncrona: qual a pressão arterial, frequência cardíaca, saturação de oxigênio, timbre da voz, umidade do ar, nível de  $CO_2$  do ar inspirado no momento de uma dor torácica, por exemplo.

## APLICAÇÕES ATUAIS E EVIDÊNCIA DE IMPACTO CLÍNICO

O rápido crescimento de tecnologias para MRP ultrapassou a capacidade de implementação estruturada de modelos de impacto clínico. Há um hiato entre a tecnologia disponível e aquela aplicada na prática clínica. Considerada a dimensão das potencialidades e a heterogeneidade das soluções, assim como os seus pilares, seja do setor de saúde, de tecnologia da informação ou de telecomunicações, torna-se desafiador avaliar os modelos propostos. Algumas soluções de MRP podem

gerar excesso de alertas inapropriados e aumentar procuras por hospitais.<sup>40</sup> Outras propostas podem sofrer interferências desde a captura de dados, a transmissão e o processamento e não detectar pacientes graves. Medir indicadores neste ambiente é complexo. A implementação na prática clínica sofre barreiras de orçamento, educação e aderência dos pacientes, especialmente os mais idosos e a integração com os diferentes sistemas e prontuários de pacientes.<sup>41</sup>

Soon et al., realizaram uma revisão da literatura sobre dispositivos para MRP.<sup>40</sup> Entre os dispositivos, adesivos, sensores embarcados em vestuário, cintas torácicas, cintas de braço e pulseiras. Estas, as mais estudadas, apresentam estudos revisados por pares confirmando sua validade e confiabilidade, assim como correlação com indicadores clínicos. Porém, concluem que há grande lacuna a ser preenchida por estudos clínicos mais robustos.

Uma revisão sistemática identificou 347 estudos e avaliou 62.<sup>41</sup> A maioria foram estudos randomizados (N=44), dez destes foram duplo cego. Houve sete estudos de coorte e um estudo caso-controle. Outros 10 foram observacionais. As características clínicas da maioria dos estudos eram de populações de pacientes crônicos. Em 23% foram doenças respiratórias (asma), em 18%, controle de peso, outros 18% foram doenças metabólicas (diabetes tipo 1 e 2) e 16% doenças cardiovasculares, predominando insuficiência cardíaca. A análise desses estudos revelou predomínio de impacto positivo quanto à custo-efetividade, assim como quanto aos indicadores clínicos avaliados, como necessidade de hospitalização.

Alguma aplicação de IA em MRP merem atenção, seja pelo alcance, ou pela diversidade de variáveis capazes de entregar análises relevantes. Senão, vejamos:

A Apple embarcou em seu relógio tecnologia de pulso-platismografia para detecção do ritmo cardíaco e eletrocardiografia de uma derivação. Em um estudo clínico, recrutou 419.297 pessoas em oito meses.<sup>42</sup> Após média de 117 dias de monitoramento remoto, 2161 participantes (0,52%) receberam notificação de pulso irregular. Um subgrupo de 450 participantes retornaram traçados de ECG analisáveis. Destes, detectou-se fibrilação atrial em 35% (97,5% CI, 27 a 43). Este estudo aponta não só o valor preditivo positivo de 84% (95% CI, 0,76 to 0,92) mas a possibilidade de conduzir um estudo clínico remotamente.

Nosso grupo publicou a aplicação de IA<sup>33</sup> para detecção de infarto do miocárdio com supradesnivelamento de ST a partir de uma única derivação de ECG, como o embarcado no relógio Apple. Este estudo aponta para as inúmeras possibilidades de IA sobre dados de MRP.

A Verily, braço de saúde da Alphabet, empresa da Google, também conduz um projeto dedicado a fibrilação atrial, em parceria com outra empresa de MRP, a iRhythm.<sup>43</sup>

Um exemplo capaz de expressar a capacidade de correlação de dados de MRP e IA pode ser visto na plataforma IMA desenvolvida pela AICURE, capaz de monitorar evolução clínica a partir de mudanças na expressão facial, através de reconhecimento facial e algoritmos de visão computacional.<sup>44</sup>

Uma das principais linhas de pesquisa em MRP está relacionada à insuficiência cardíaca (IC), especialmente por seu impacto em hospitalização e como causa de mortalidade. Em metanálise de 26 estudos que avaliaram impacto da MRP sobre a re-hospitalização e mortalidade, Pekmezaris et al.,

identificaram redução de mortalidade por todas as causas e por insuficiência cardíaca aos 180 dias, mas não aos 360. Não houve redução de hospitalização por qualquer causa, nem mesmo por IC. Houve aumento de visitas ao pronto socorro no grupo que recebeu MRP.<sup>45</sup>

A associação de IA ao telemonitoramento tem recebido muita atenção, em busca de aprimorar as plataformas e melhorar o cuidado dos pacientes crônicos.

Pesquisadores da Universidade de Washington cadastraram no registro americano de estudos clínicos um estudo que integra Apple Watch e Fitbit a uma Plataforma que emprega IA sobre os dados coletados remotamente de pacientes com IC com fração de ejeção reduzida.<sup>46</sup> A Plataforma integrará dados de balança, pulso-platismografia, ECG, acelerômetro, pressão arterial, oximetria, entre outros.

## CONSIDERAÇÕES FINAIS

O MRP vem experimentando transformações devido a dois aspectos fundamentais, o primeiro tem sido o impacto regulatório associado à percepção do benefício logo após a pandemia Covid. Provedores de saúde e pacientes experimentaram diferentes aplicações de MRP que modificaram indicadores. Isso parece irreversível. O Segundo aspecto deriva da evolução tecnológica fomentada pela aceitação do mercado de saúde. A telemedicina, empoderada pelo MRP ganha informações relevantes para o diagnóstico e tratamento de pacientes.

O primeiro resultado dessa transformação, e talvez o mais importante, é o volume e qualidade de dados coletados. Estima-se mudança transformadora de uma coleta vertical, por visita presencial, para uma abordagem horizontal, ao longo das 24 horas do dia dos pacientes e suas ecologias, seus ambientes. O tratamento analítico desses dados por diferentes algoritmos e sua integração a protocolos clínicos, seguramente entregará indicadores robustos, especialmente sobre doenças crônicas, como diabetes, hipertensão arterial, doença pulmonar, entre outros. Não desprezíveis são as aplicações para urgência e emergência, tanto na predição, quanto na detecção precoce, desde o ambiente dos pacientes, como no caso do infarto agudo do miocárdio. O exemplo do infarto pode ilustrar o cenário. A detecção de um infarto no domicílio do paciente pode deflagrar o despacho automático de uma ambulância geo-referenciada, que o transportará, continuamente monitorado e em contato com o hospital de referência, evitando hospitais inadequados, dispensando a etapa do pronto socorro e, ao longo do trajeto, iniciando o tratamento definido por protocolo compartilhado. Esse paciente será levado diretamente à sala de hemodinâmica. Toda a equipe envolvida será acionada pelos dispositivos móveis, recebendo os traçados de ECG e informações relevantes. Desde o primeiro contato, o sistema utilizará *natural language understanding* que conversará com o paciente, “entenderá” os sintomas, associará com o prontuário do paciente e recomendará à equipe médica baseada em diretrizes. Parece ficção, mas desde a detecção do infarto, até a reperfusão, todas as etapas tecnológicas descritas aqui já estão disponíveis e já foram aplicadas na prática clínica.

Assim, o potencial de MRP associado à IA se estende muito além da simples transmissão de dados de um lado a outro. Essa associação propicia cuidado proativo capaz de se antecipar a eventos sem a necessidade de visita física do

paciente. Além da atuação sobre a doença, há enorme oportunidade de promoção de hábitos saudáveis, sem qualquer intervenção médica. O caminho natural será a implementação de cuidado personalizado, gerado pelo constante aprendizado da IA sobre os dados contínuos de cada paciente.

## CONFLITOS DE INTERESSE

Os autores declaram não possuir conflitos de interesse na realização deste trabalho.

## REFERÊNCIAS

1. Wickramasinghe N, John B, George J, Vogel D. Achieving value-based care in chronic disease management: intervention study. *JMIR Diabetes* 2019;4(2):e10368.
2. Centre for Diseases Control. National Center for Chronic Disease Prevention and Health Promotion (NCCDPHP). Available from: <https://www.cdc.gov/chronicdisease/about/index.htm>.
3. Malasinghe LP, Ramzan N, Dahal K. Remote patient monitoring: a comprehensive study.
4. *J Ambient Intell Human Comput.* 2019;10:57–76 4. Hilty DM, Armstrong CM, Edwards –Stewart A, Gentry MT, Luxton DD, Krupinski EA. Sensor, Wearable, and Remote Patient Monitoring Competencies for Clinical Care and Training: Scoping Review. *J Technol Behav Sci.* 2021; 6:252–277
5. Walker RC, Tong A, Howard K, Palmer SC. Patient expectations and experiences of remote monitoring for chronic diseases: Systematic review and thematic synthesis of qualitative studies. *Int J Med Inform.* 2019;124:78-85
6. Ferguson C, Hickman L, Türkmani S, Eng PBB, Gargiulo GD, Inglis SC. "Wearables only work on patients that wear them": Barriers and facilitators to the adoption of wearable cardiac monitoring technologies *Cardiovasc Dig Health J.* 2021;2:137–47
7. Intel. Over 50 years of Moore's law. Available from: <https://www.intel.com/content/www/us/en/silicon-innovations/moores-law-technology.html>
8. Arute F, Arya K, Babbush R, Bacon D, Bardin JC, Barends R. Quantum supremacy using a programmable superconducting processor. *Nature.* 2019;574(7779):505-10.
9. Cash KJ, Clark HA. Nanosensors and nanomaterials for monitoring glucose in diabetes. *Trends Mol Med.* 2010; 16(12): 584–93.
10. Regulatory Agency. 2018. Medical devices: software applications (apps). Medicines and Healthcare products. Regulatory Agency. Available at: <https://www.gov.uk/government/publications/medical-devices-software-applications-apps>
11. Arora S, Yttri J, Nilsen W. Privacy and Security in Mobile Health (mHealth) Research. *Alcohol Res.* 2014; 36(1): 143–51.
12. Pelaccia T, Forestier G, Wemmert C. Deconstructing the diagnostic reasoning of human versus artificial intelligence. *CMAJ.* 2019;191(48):E1332-5.
13. Jeddi Z, Bohr A. Remote Patient Monitoring Using Artificial Intelligence. In: Adam Bohr and Kaveh Memarzadeh. *Artificial Intelligence in Healthcare.* Massachusetts: Academic Press. 2020
14. Islam R, Kwak D, Kabir H, Hossain M, Kwak K-S. The Internet of Things for Health Care: A Comprehensive Survey. *IEEE Access.* 2015;3:678-708. Available from: <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=7113786>
15. Michele R, Furini M. IoT Healthcare: Benefits, Issues and Challenges. 2019. Available from: [https://www.researchgate.net/publication/335215280\\_IoT\\_Healthcare\\_Benefits\\_Issues\\_and\\_Challenges](https://www.researchgate.net/publication/335215280_IoT_Healthcare_Benefits_Issues_and_Challenges)
16. Deloitte. Global Health Care Outlook. In Research Report. 2019. Available at: <https://www2.deloitte.com/global/en/pages/life-sciences-andhealthcare/articles/global-health-care-sector-outlook.html>.)
17. Tuohy JP. Sengled's newest smart bulb can track your heart rate. 2022. Available from: <https://www.theverge.com/2022/1/3/22864783/sengled-smart-health-monitoring-smart-bulb-ces2022>
18. Hartmann M, Hashmi US, Imran A. Edge computing in smart health care systems: Review, challenges, and research directions. *Transactions on Emerging Telecommunications Technologies.* 2019. <https://doi.org/10.1002/ett.3710>
19. Yan BP, Lai WHS, Chan CKY, Au ACK, Freedman B, Poh YC, et al. High-Throughput, Contact-Free Detection of Atrial Fibrillation From Video With Deep Learning. *JAMA Cardiol.* 2020;5(1):105-7.
20. Bonomi F, Milito R, Natarajan P, Zhu J. Fog Computing: A Platform for Internet of Things and Analytics. *Big Data and Internet of Things: A Roadmap for Smart Environments.* 2014;169-86 Available from: [https://cse.buffalo.edu/faculty/tkosar/cse710\\_spring19/bonomi-bdiot14.pdf](https://cse.buffalo.edu/faculty/tkosar/cse710_spring19/bonomi-bdiot14.pdf)
21. 5G in Healthcare. How the new wireless standard can connect a post-Covid healthcare ecosystem. PWC. Available from: <https://www.pwc.com/gx/en/industries/tmt/5g/pwc-5g-in-healthcare.pdf>
22. Eid A, Hester JGD, Tentzeris MM. 5G as a wireless power grid. *Sci Rep.* 2021; 11(1): 636. doi: 10.1038/s41598-020-79500-x
23. Schneier B. Data is a toxic asset. 2016. Available from: [https://www.schneier.com/blog/archives/2016/03/data\\_is\\_a\\_toxic.html#:~:text=Thefts%20of%20personal%20information%20aren,to%20Experian%20and%20the%20IRS](https://www.schneier.com/blog/archives/2016/03/data_is_a_toxic.html#:~:text=Thefts%20of%20personal%20information%20aren,to%20Experian%20and%20the%20IRS).
24. Gupta M. *Blockchain for Dummies.* New Jersey: IBM Limited Edition, 2017.
25. Cerqueira AH, Steler FW. Tudo o que você queria saber sobre blockchain e tinha receio de perguntar. 2017. Disponível em: <<https://computerworld.com.br/inovacao/tudo-o-que-voce-queria-saber-sobre-blockchain-e-tinha-receio-de-perguntar>>
26. Rocha L. eCash: Como a criação de David Chaum deu início ao sonho cyberpunk. *Bet365.* 2018. Disponível em: <<https://www.criptofacil.com/ecash-como-a-criacao-de-david-chaum-deu-inicio-ao-sonho-cyberpunk/>> .
27. Sharma R, Rasure E, Munichiello K. What is bit Gold? *Bit Gold.* 2021. Disponível em: <<https://www.investopedia.com/terms/b/bit-gold.asp>> .
28. Simply Tecnologia. Blockchain: saiba o que é e como pode ser usado pelos Bancos. 2016. Disponível em: <<https://blog.simply.com.br/blockchain-saiba-o-que-e-e-como-pode-ser-usado/>>
29. Marco Polo Network. Insights: Difference Blockchain and DLT. 2018. Disponível em: <<https://marcopolonetwork.com/articles/distributed-ledger-techn>>
30. Breidenbach L, Cachin C, Chan B, Coventry A, Ellis S, Miller A, et al. Chainlink 2.0: Next Steps in the Evolution of Decentralized Oracle Networks. 2021. Disponível em: <<https://research.chainlink.com/whitepaper-v2.pdf>>
31. Ratta P, Kaur A, Sharma S, Shabaz M, Dhiman G. Application of Blockchain and Internet of Things in Healthcare and Medical Sector: Applications, Challenges, and Future Perspectives. *Hindawi Journal of Food Quality.* 2021. <https://doi.org/10.1155/2021/7608296>
32. Topol E. *Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again.* New York: Basic Books. 2019
33. Gibson CM, Mehta S, Ceschim MRS, Frauenfelder A, Vieira D, Botelho R, et al. Evolution of single-lead ECG for STEMI detection using a deep learning approach. *Int J Cardiol.* 2022; 346:47-52
34. Pelaccia T, Forestier G, Wemmert C. Deconstructing the



- diagnostic reasoning of human versus artificial intelligence. *CMAJ*. 2019;191(48):E1332-5. doi: 10.1503/cmaj.190506
35. Avila CO. Novel Use of Apple Watch 4 to Obtain 3-Lead Electrocardiogram and Detect Cardiac Ischemia. *Perm J*. 2019;23:19-25.
36. Wang H, Liu Y, Zhen X, Tu X. Depression Speech Recognition With a Three-Dimensional Convolutional Network. *Front. Hum. Neurosci*. 2021 15:713823
37. Kocaman V, Talby D. Spark NLP: Natural Language Understanding at Scale. *Software Impacts*. 2021;8: 100058
38. Ceusters W, Lorré J, Harnie A, Van Den Bossche B, Demoor G. Developing natural language understanding applications for healthcare: a case study on interpreting drug therapy information from discharge summaries. Available from: <http://www.referent-tracking.com/RTU/files/FreepharmaWG6/1.0/FreepharmaWG6.pdf>
39. Winward S, Patel T, Al-Saffar M, Noble M. The Effect of 24/7, Digital-First, NHS Primary Care on Acute Hospital Spending: Retrospective Observational Analysis. *J Med Internet Res*. 2021;23(7):e24917
40. Soon S, Svavarsdottir H, Downey C, et al. Wearable devices for remote vital signs monitoring in the outpatient setting: an overview of the field. *BMJ Innov* 2020;6:55–71.
41. Vegesna A, Tran M, Angelaccio M, Arcona S. Remote Patient Monitoring via Non-Invasive Digital Technologies: A Systematic Review. *Telemed J E Health*. 2017;23(1):3-17. doi: 10.1089/tmj.2016.0051
42. Perez MV, Mahaffey KW, Hedlin H, Rumsfeld J, Garcia A, Ferris T, et al. Large-Scale Assessment of a Smartwatch to Identify Atrial Fibrillation. *N Engl J Med*. 2019;381(20):1909-17. <https://pubmed.ncbi.nlm.nih.gov/31722151/>
43. Gladstone DJ, Wachter R, Schmalstieg-Bahr K, Quinn FR, Hummers E, Ivers N, et al. Screening for Atrial Fibrillation in the Older Population: A Randomized Clinical Trial. *JAMA Cardiol*. 2021; 6(5):558-67. doi: 10.1001/jamacardio.2021.0038. <https://pubmed.ncbi.nlm.nih.gov/33625468/>
44. Computer Vision Platform to Remotely Capture Digital Biomarkers in Clinical Trials. Available from: <https://www.prnewswire.com/news-releases/aicure-introduces-industrys-first-computer-vision-platform-to-remotely-capture-digital-biomarkers-in-clinical-trials-301047942.html>
45. Pekmezaris R, Torte L, Williams M, Patel V, Makaryus A, Zeltser R, et al. Home Telemonitoring In Heart Failure: A Systematic Review And Meta-Analysis. *Health Aff*. 2018; 37(12): 1983–9. <https://pubmed.ncbi.nlm.nih.gov/30633680/>
46. Evald G, et al. Remote Monitoring of Multiple Indicators of Heart Failure. Available from: <https://clinicaltrials.gov/ct2/show/NCT04267744>

# APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL EM IMAGEM CARDIOVASCULAR: EM TOMOGRAFIA COMPUTADORIZADA E RMN

## APPLICATION OF ARTIFICIAL INTELLIGENCE IN CARDIAC IMAGING: COMPUTED TOMOGRAPHY AND MAGNETIC RESONANCE IMAGING

Gilberto Szarf<sup>1,2</sup>  
Cesar H. Nomura<sup>3,4</sup>

1. Hospital Israelita Albert Einstein. Departamento de Diagnóstico por Imagem. São Paulo, SP, Brasil.  
2. Universidade Federal de São Paulo. São Paulo, SP, Brasil.  
3. Hospital Sírio – Libanês. São Paulo, SP, Brasil.  
4. Instituto do Coração - InCor-HCFMUSP. São Paulo, SP, Brasil.

Correspondência:  
Gilberto Szarf  
gszarf@yahoo.com.br

### RESUMO

Ao longo dos últimos anos, foram desenvolvidos conhecimentos relacionados à aplicação de IA em imagens médicas. O resultado disso é que hoje temos algoritmos sendo desenvolvidos para pesquisa e outros disponíveis para serem incorporados em nossa prática. Este artigo oferece uma visão relacionada às possíveis aplicações de IA que podem auxiliar ao longo da jornada dos pacientes para os quais foi solicitada uma tomografia computadorizada ou uma ressonância magnética do coração. Perspectivas futuras também são alvo de comentários.

**Descritores:** Angiografia por Tomografia Computadorizada; Tomografia Computadorizada Multidetectors; Imageamento por Ressonância Magnética; Inteligência Artificial.

### ABSTRACT

*Knowledge about the opportunities for AI in medical imaging has advanced during the last few years. Today, as a result, we have some AI algorithms that are being developed for research and others available to be incorporated into our clinical environment. This article provides an insight into the AI applications that can be of assistance during the patient journey for whom a cardiac CT or MRI scan has been requested. Future perspectives are also discussed.*

**Keywords:** Computed Tomography Angiography; Multidetector Computed Tomography; Magnetic Resonance Imaging; Artificial Intelligence.

Inteligência artificial (IA) é um termo que se refere ao uso de computadores para desempenhar ações que habitualmente são realizadas por humanos, com mínima ou nenhuma intervenção destes, de forma autônoma. O aprendizado de máquina, em inglês *machine learning* (ML) é um ramo da IA, que pode ser utilizado para analisar informações, descobrir padrões e se modificar baseado na exposição a exemplos positivos e negativos, conseguindo assim desenvolver a capacidade desempenhar tarefas como classificação de imagens, reconhecimento de voz, reconhecimento de objetos, tradução de linguagem e processamento de linguagem natural. Já aprendizagem profunda, *deep learning* em inglês (DL), é uma forma de ML que utiliza algoritmos com redes neurais para realizar as tarefas.<sup>1</sup>

Em um momento em que as taxas de esgotamento profissional (*burnout*) chamam a atenção, os algoritmos de aprendizagem profunda, oferecem a perspectiva da realização automática de várias tarefas que consomem tempo, contribuem para a exaustão e para a sensação de falta de realização em médicos que trabalham com diagnóstico por imagem.<sup>2</sup> Um fator importante para o sucesso da implementação deste

tipo de tecnologia é que o seu desenvolvimento seja realizado com base nos usuários, em colaboração com eles, para maximizar sua utilização.<sup>3</sup> Desta forma, acreditamos que esta especialidade médica sofrerá profundas transformações com a adoção deste tipo de tecnologia, possivelmente resolvendo tarefas maçantes e liberando tempo para que os médicos possam atuar onde são mais necessários, no cuidado ao paciente.<sup>4</sup>

Os algoritmos de IA podem ser utilizados em diferentes etapas do atendimento aos pacientes que precisam fazer exames de imagem. A seguir veremos alguns exemplos, com especial atenção à tomografia computadorizada e à ressonância magnética do coração.

### REALIZAÇÃO DO EXAME

A realização da ressonância magnética do coração depende de técnicos, tecnólogos ou biomédicos adequadamente treinados na aquisição de imagens nos planos cardíacos, que são diferentes dos adotados nos exames de diferentes partes do corpo humano. Para isso eles devem conhecer a anatomia cardíaca ou têm de recorrer a alguém que possa

orientá-los. Durante e após a realização do exame, a qualidade do mesmo deve ser aferida, para se ter certeza de que tenha atingido padrão suficiente para análise. Entre outros fatores, a capacidade do paciente de realizar apneias repetidas e de tolerar cerca de 30 minutos em uma mesma posição dentro do equipamento são determinantes.

Profissionais treinados e certificados podem ser encontrados em centros maiores e mais especializados, porém por vezes tal qualificação pode não estar presente em centros menores ou mais remotos. Desta forma, a aferição automática da qualidade dos estudos, como proposto por Piccini e col., pode ajudar quando não há alguém qualificado para isto.<sup>5</sup>

Ainda no sentido de ajudar no momento da realização do exame, algoritmos foram propostos para otimizar a aquisição das imagens, automatizando a prescrição do exame, com o intuito de tornar a aquisição das imagens uniforme, com elevado padrão de qualidade, tornando a mesma acessível a centros que não disponham de profissionais com tal qualificação.<sup>6</sup>

Mecanismos de aceleração da aquisição das imagens também estão disponíveis, encurtando a duração dos exames, trazendo maior conforto para os pacientes e possibilitando um maior fluxo de atendimento em um mesmo equipamento.<sup>7</sup>

Em relação à aquisição das imagens pela tomografia computadorizada, a inteligência artificial oferece o potencial de otimizar a reconstrução de imagens, frente aos mecanismos dos quais dispomos hoje.<sup>8</sup> Com esta otimização, é possível reduzir as doses de radiação às quais os pacientes são expostos.

## ANÁLISE DAS IMAGENS E QUANTIFICAÇÃO DOS ACHADOS

No campo da ressonância magnética, a análise da função cardíaca, em especial a função sistólica ventricular, é uma etapa cansativa e que consome tempo, pois requer a planimetria manual das cavidades cardíacas. A automação desta etapa já foi proposta, contribuindo para que o médico possa realizar outras tarefas de maior benefício para seus pacientes.<sup>9,10</sup>

Da mesma forma, já foi demonstrado que a detecção através da RM de realce tardio miocárdico e sua classificação (focal, epicárdico, subendocárdico, transmural, não diagnóstico, mesocárdico) também pode ser realizada por algoritmos de DL.<sup>11</sup>

Já no campo da tomografia computadorizada, algoritmos foram propostos para extrair automaticamente os resultados de escore de cálcio coronariano (CAC) a partir de tomografias do tórax, assim como existem publicações que propõem algoritmos para detecção de lesões obstrutivas e não obstrutivas na angiogramografia das artérias coronárias.<sup>12-16</sup>

Mas a importância da inteligência artificial na angiogramografia de coronárias teve maior evidência e relevância com o desenvolvimento do FFR-CT (reserva de fluxo fracionada por tomografia computadorizada) que é a quantificação não invasiva da reserva de fluxo miocárdico. Particularmente útil em estenoses moderadas (50% a 69%), podendo ajudar na correta discriminação de quais destas estão associadas à isquemia.<sup>17</sup>

Estudos demonstraram que a tomografia de coronárias tem elevada acurácia para identificar isquemia miocárdica por meio da quantificação não invasiva da FFRTC quando comparada ao padrão-ouro, a FFR invasiva pelo cateterismo cardíaco (FFRi).<sup>18,19</sup>


Mais recentemente o FFR-CT saiu do âmbito do processamento em supercomputadores e da necessidade de um tempo maior de análise para uma solução mais rápida, simples e acessível, utilizando a Inteligência Artificial como viabilizadora desta tecnologia. Este novo modelo de processamento permite que a análise da reserva de fluxo coronário por tomografia seja realizada em estação de trabalho *in loco* nos hospitais.

Empresas tradicionais fabricantes de tomógrafos já apresentam esta tecnologia validada, porém apenas para a utilização como pesquisa e não para uso na prática clínica. Todas estas tecnologias existentes ainda necessitam a interferência do ser humano para validação e correção das imagens, principalmente no delineamento e marcação da árvore coronariana.

As etapas para cálculo da FFRTC de processamento *in loco* estão demonstradas na Figura 1. Esse programa foi desenvolvido com nova ferramenta de inteligência artificial, utilizando-se técnicas de ML. O tempo total de pós-processamento de todas as etapas foi em torno de 10 minutos, no entanto, casos mais complexos podem consumir mais tempo.<sup>20</sup>

## PREDIÇÃO DE DESFECHOS

Algoritmos de ML podem melhorar a acurácia de testes diagnósticos.<sup>21</sup> A integração de dados clínicos e de imagem



**Figura 1.** Etapas do FFR-CT A) Detecção visual da lesão coronariana. B) Definição da linha central (centerline) e contornos luminiais C) pelo program) definição dos limites da lesão e do ponto de maior redução luminal pelo operador. E) Resultado do FFR no ponto de maior redução luminal demonstrado na árvore coronariana com diâmetro mínimo de análise de 1,5mm.

por ML também pode melhorar a predição prognóstica de desfechos, como demonstrado em um estudo que levou em conta parâmetros de imagem por tomografia computadorizada do coração e parâmetros clínicos, demonstrando que um algoritmo de ML apresentou área abaixo da curva maior que o escore de risco de Framingham e que um escore de gravidade tomográfico para predizer mortalidade.<sup>22</sup>

Interessante lembrar que estes algoritmos podem encontrar novas pistas em grandes volumes de dados, anteriormente não consideradas.

## OUTRAS APLICAÇÕES

Além disto, em outras áreas do diagnóstico por imagem, já foi demonstrado que algoritmos podem ajudar a identificar achados críticos e realizar a notificação da equipe médica, para que ações sejam implementadas em tempo mais curto.<sup>23</sup> É possível que ferramentas semelhantes sejam desenvolvidas para a avaliação de lesões encontradas na angiotomografia das artérias coronárias. Outra ação interessante é a orquestração da rotina de trabalho do profissional de imagem, antecipando as análises de exames com achados mais preocupantes, encontrados automaticamente, ou mesmo direcionando exames para serem analisados por profissionais que tenham maior experiência nos achados automaticamente detectados nas imagens.<sup>24</sup>

Oportunidades potenciais a serem exploradas também incluem a análise de agrupamento (*cluster analysis*) em que grupos homogêneos são separados com base em padrões

encontrados nos dados. Possíveis grupos fenotípicos diferentes podem ser encontrados para uma mesma doença a partir de dados de imagem, muitas vezes em associação com dados clínicos.<sup>25</sup>

## CONCLUSÃO

Como mencionado acima, vários algoritmos têm sido propostos para auxiliar em diferentes momentos do atendimento ao paciente. Conforme eles forem clinicamente validados, por vezes necessitando de ajustes em populações diferentes das quais onde foram criados e treinados, o que se espera é que eles passem a ser incorporados, trabalhando ao fundo, ajudando na aquisição das imagens, no controle de qualidade, detectando achados sensíveis e priorizando as análises dos mesmos, oferecendo ainda quantificações e classificações automáticas, além de poderem se integrar a outras informações presentes no prontuário eletrônico, podendo oferecer melhor previsão de desfechos. O que se desenha é um cenário em que o profissional de saúde, auxiliado pela inteligência artificial, apresente ganho de produtividade e de qualidade com a incorporação destes novos algoritmos.

## CONFLITOS DE INTERESSE

Os autores declaram não possuir conflitos de interesse na realização deste trabalho.

## REFERÊNCIAS

1. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521(7553):436–44.
2. Ganeshan D, Rosenkrantz AB, Bassett RL Jr, Williams L, Lenchik L, Yang W. Burnout in Academic Radiologists in the United States. *Acad Radiol*. 2020;27(9):1274–81.
3. Filice RW, Ratwani RM. The Case for User-Centered Artificial Intelligence in Radiology | *Radiology: Artificial Intelligence*. 2020;2(3):e190095. Disponível em: <https://pubs.rsna.org/doi/full/10.1148/ryai.2020190095>
4. Langlotz CP. Will Artificial Intelligence Replace Radiologists? | *Radiology: Artificial Intelligence*. 2019;1(3). Disponível em: <https://pubs.rsna.org/doi/full/10.1148/ryai.2019190058>
5. Piccini D, Demesmaeker R, Heerfordt J, Yerly J, Di Sopra L, Masci PG, et al. Deep Learning to Automate Reference-Free Image Quality Assessment of Whole-Heart MR Images | *Radiology: Artificial Intelligence*. 2020;2(3). Disponível em: <https://pubs.rsna.org/doi/full/10.1148/ryai.2020190123>
6. Blansit K, Retson T, Masutani E, Bahrami N, Hsiao A. Deep Learning-based Prescription of Cardiac MRI Planes. *Radiol Artif Intell*. 2019;1(6):e180069.
7. Bash S, Wang L, Airriess C, Zaharchuk G, Gong E, Shankaranarayanan A, et al. Deep Learning Enables 60% Accelerated Volumetric Brain MRI While Preserving Quantitative Performance: A Prospective, Multicenter, Multireader Trial. *Am J Neuroradiol*. 2021;42(12):2130–7.
8. Shan H, Padole A, Homayounieh F, Kruger U, Khera RD, Nitwarangkul C, et al. Competitive performance of a modularized deep neural network compared to commercial algorithms for low-dose CT image reconstruction. *Nature Machine Intelligence*. 2019;1:269–76. Disponível em: <https://www.nature.com/articles/s42256-019-0057-9>
9. Tan LK, Liew YM, LE, McLaughlin RA. Convolutional neural network regression for short-axis left ventricle segmentation in cardiac cine MR sequences. *Med Image Anal*. 2017;39:78–86. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1361841517300543?via%3Dihub#abs0002>
10. Ruijsink B, Puyol-Antón E, Oksuz I, Sinclair M, Bai W, Schnabel JA, et al. Fully Automated, Quality-Controlled Cardiac Analysis From CMR: Validation and Large-Scale Application to Characterize Cardiac Function. *JACC Cardiovasc Imaging*. 2020;13(3):684–95. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1936878X19305856?via%3Dihub>
11. Ohta Y, Yunaga H, Kitao S, Fukuda T, Ogawa T. Detection and Classification of Myocardial Delayed Enhancement Patterns on MR Images with Deep Neural Networks: A Feasibility Study. *Radiol Artif Intell*. 2019;1(3):e180061.
12. Eng D, Chute C, Khandwala N, Rajpurkar P, Long J, Shleifer S, et al. Automated coronary calcium scoring using deep learning with multicenter external validation. *npj Digital Medicine*. 2021;88(4). Disponível em: <https://www.nature.com/articles/s41746-021-00460-1>
13. Takx RAP, Jong PA, Leiner T, Oudkerk M, Koning HJ, Mol CP, et al. Automated Coronary Artery Calcification Scoring in Non-Gated Chest CT: Agreement and Reliability. *Plos One*. 2014;9(3):e91239.
14. Isgum I, Prokop M, Niemeijer M, Viergever MA, van Ginneken B. Automatic Coronary Calcium Scoring in Low-Dose Chest Computed Tomography. *IEEE Trans Med Imaging*. 2012;31(12):2322–34.
15. Kang D, Dey D, Slomka PJ, Arsanjani R, Nakazato R, Ko H, et al. Structured learning algorithm for detection of nonobstructive and obstructive coronary plaque lesions from computed tomography angiography. *J Med Imaging*. 2015;2(1):014003.
16. Dey D, Gaur S, Ovrehus KA, Slomka PJ, Betancur J, Goeller M, et al. Integrated prediction of lesion-specific ischaemia from quantitative coronary CT angiography using machine learning: a multicentre study. *Eur Radiol*. 2018;28(6):2655–64.
17. Koo B-K, Erglis A, Doh J-H, Daniels DV, Jegere S, Kim H-S, et al. Diagnosis of ischemia-causing coronary stenoses by noninvasive fractional flow reserve computed from coronary computed

- tomographic angiograms. Results from the prospective multicenter DISCOVER-FLOW (Diagnosis of Ischemia-Causing Stenoses Obtained Via Noninvasive Fractional Flow Reserve) study. *J Am Coll Cardiol*. 2011;58(19):1989–97.
18. Min JK, Leipsic J, Pencina MJ, Berman DS, Koo B-K, van Mieghem C, et al. Diagnostic Accuracy of Fractional Flow Reserve From Anatomic CT Angiography. *JAMA*. Disponível em: <https://jamanetwork.com/journals/jama/fullarticle/1352969>
19. Norgaard BL, Leipsic J, Gaur S, Seneviratne S, Ko BS, Ito H, et al. Diagnostic Performance of Noninvasive Fractional Flow Reserve Derived From Coronary Computed Tomography Angiography in Suspected Coronary Artery Disease: The NXT Trial (Analysis of Coronary Blood Flow Using CT Angiography: Next Steps). *J Am Coll Cardiol*. 2014;63(12):1145–55.
20. Morais TC, Assunção-Jr AN, Dantas Júnior RN, Silva CFG, Paula CB de, Torres RA, et al. Performance Diagnóstica da FFR por Angiotomografia de Coronárias através de Software Baseado em Inteligência Artificial. *Arq Bras Cardiol*. 2021;116(6):1091–8.
21. Tesche C, De Cecco CN, Baumann S, Renker M, McLaurin TW, Duguay TM, et al. Coronary CT Angiography–derived Fractional Flow Reserve: Machine Learning Algorithm versus Computational Fluid Dynamics Modeling. *Radiology*. 2018;288(1):64–72.
22. Motwani M, Dey D, Berman DS, Germano G, Achenbach S, Al-Mallah MH, et al. Machine learning for prediction of all-cause mortality in patients with suspected coronary artery disease: a 5-year multicentre prospective registry analysis. *Eur Heart J*. 2017;38(7):500–7.
23. Prevedello LM, Erdal BS, Ryu JL, Little KJ, Demirer M, Qian S, et al. Automated Critical Test Findings Identification and Online Notification System Using Artificial Intelligence in Imaging. *Radiology*. 2017;285(3):923–31.
24. PHCIS\_Brochure\_07-Workflow\_Orchestrator.pdf [Internet]. [citado 18 de fevereiro de 2022]. Disponível em: [https://www.philips.com/c-dam/b2bhc/master/landing-pages/caestream/enterprise-imaging-platform/brochures/PHCIS\\_Brochure\\_07-Workflow\\_Orchestrator.pdf?\\_ga=2.129245772.1363499615.1603619555-1404508323.1587556455](https://www.philips.com/c-dam/b2bhc/master/landing-pages/caestream/enterprise-imaging-platform/brochures/PHCIS_Brochure_07-Workflow_Orchestrator.pdf?_ga=2.129245772.1363499615.1603619555-1404508323.1587556455)
25. Zheng Q, Delingette H, Fung K, Petersen SE, Ayache N. Pathological Cluster Identification by Unsupervised Analysis in 3,822 UK Biobank Cardiac MRIs. *Front Cardiovasc Med*. 2020;7:539788. Disponível em: <https://www.frontiersin.org/article/10.3389/fcvm.2020.539788>

# APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL EM IMAGEM CARDIOVASCULAR: CLASSIFICAÇÃO AUTOMÁTICA DE IMAGENS DE RADIOGRAFIA DE TÓRAX

## APPLICATION OF ARTIFICIAL INTELLIGENCE IN CARDIOVASCULAR IMAGING: AUTOMATIC CLASSIFICATION OF CHEST RADIOGRAPHY IMAGES

Marco Antonio Gutierrez<sup>1</sup>  
Diego Armando Cardona Cardenas<sup>1</sup>  
Karem Daiane Marcomini<sup>2</sup>  
Agma Juci Machado Traina<sup>2</sup>  
Ramon Alfredo Moreno<sup>1</sup>  
José Eduardo Krieger<sup>1</sup>

1. Instituto do Coração (InCor), Hospital das Clínicas da Universidade de São Paulo, SP, Brasil  
2. Universidade de São Paulo, Instituto de Ciências Matemáticas e de Computação (ICMC), São Carlos, SP, Brasil.

Correspondência  
Marco Antonio Gutierrez  
marco.gutierrez@incor.usp.br

### RESUMO

Avanços recentes na área de inteligência artificial, especialmente em aprendizagem profunda, levaram a um desempenho promissor em muitas tarefas de análise e processamento de imagens médicas. Como exame radiológico mais comumente realizado, a radiografia de tórax é uma modalidade particularmente importante para a qual uma variedade de métodos e aplicações tem sido proposta. Paralelamente, com a crescente disponibilização de vários conjuntos de dados de raios-X de tórax (CXR), muitos deles, com dezenas de milhares de exames e publicamente disponíveis nos últimos anos, motivaram o interesse na pesquisa e o desenvolvimento nessa área. Neste artigo, apresentamos uma breve revisão de alguns dos estudos recentes que envolvem a aprendizagem profunda em radiografia de tórax, bem como os principais conceitos que envolvem redes neurais artificiais e a capacidade dessas redes nas tarefas de classificação, segmentação e localização de lesões a partir das informações presentes na imagem.

**Descritores:** Inteligência Artificial; Radiografia; Tórax; Classificação.

### ABSTRACT

Recent advances in artificial intelligence, especially in deep learning, have led to promising performance in many medical image processing and analysis tasks. As the most performed radiological examination, chest radiography is a particularly important modality for which a variety of methods and applications have been proposed. In parallel, the increasing availability of several chest X-ray (CXR) datasets, many of them with tens of thousands of exams made publicly available in recent years, has motivated interest in research and development in this area. In this article, we present a brief review of some of the recent studies involving deep learning for chest radiography, as well as the main concepts involving artificial neural networks and their ability to classify, segment, and localize lesions from the information present in the image.

**Descriptors:** Artificial Intelligence; Radiography; Thorax; Classification.

### INTRODUÇÃO

A avaliação de doenças baseada em imagens médicas depende muito da interpretação de imagens. Essa tarefa era realizada quase inteiramente pelos especialistas humanos nos primeiros anos da imagiologia médica. 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 obterem diagnósticos mais precisos.<sup>1-3</sup>

Dentre as diferentes modalidades de imagens médicas, a radiografia de tórax (raio-X de tórax ou CXR) continua sendo o exame radiológico mais comumente realizado no mundo, com países industrializados relatando uma média de 238 imagens CXR por 1.000 habitantes anualmente.<sup>4</sup> Em 2006, estima-se

que 129 milhões de imagens de CXR foram adquiridas somente nos Estados Unidos,<sup>5</sup> sendo que no Brasil contamos com cerca de 97,6 equipamentos de Raio-X por milhão de habitantes.<sup>4</sup> A demanda e a disponibilidade de imagens de CXR podem ser atribuídas ao seu custo-benefício e baixa dose de radiação, combinados com uma sensibilidade razoável para uma ampla variedade de patologias. A radiografia torácica é frequentemente o primeiro estudo de imagem adquirido, sendo fundamental para triagem, diagnóstico e tratamento de uma ampla gama de patologias.<sup>6</sup> As radiografias de tórax podem ser divididas em três tipos principais, de acordo com a posição e orientação do paciente em relação à fonte de raios X e painel detector: posteroanterior, anteroposterior e lateral. As incidências pósterio-anterior (PA) e ântero-posterior

(AP) são ambas consideradas frontais, com a fonte de raios X posicionada na parte posterior ou frontal do paciente, respectivamente. A imagem AP é tipicamente adquirida de pacientes na posição supina, enquanto o paciente geralmente está em pé para a aquisição da imagem PA. A imagem lateral (LA) é geralmente adquirida em combinação com uma imagem PA e projeta a radiografia de um lado do paciente para o outro, normalmente da direita para a esquerda. Exemplos destes tipos de imagem estão representados na Figura 1.

A interpretação da radiografia de tórax pode ser desafiadora devido à sobreposição de estruturas anatômicas ao longo da direção de projeção. Esse efeito pode tornar muito difícil detectar anormalidades em locais específicos (por exemplo, um nódulo posterior ao coração em uma radiografia frontal), detectar pequenas ou sutis alterações ou distinguir com precisão entre diferentes padrões patológicos. Por essas razões, os radiologistas normalmente apresentam alta variabilidade inter-observador em suas análises de radiografia torácica.<sup>7-9</sup> O volume de imagens CXR adquiridas, a complexidade de sua interpretação e seu valor na prática clínica há muito motivam os pesquisadores a construir algoritmos automatizados para análise dessa modalidade. De fato, esta tem sido uma área de interesse de pesquisa desde a década de 1960, quando foram publicados os primeiros artigos descrevendo um sistema automatizado de detecção de anormalidades em imagens CXR.<sup>10-13</sup> Os ganhos potenciais da análise automatizada de imagens CXR incluem maior sensibilidade para achados sutis, priorização de casos sensíveis ao tempo, automação de tarefas diárias tediosas e fornecimento de análise em situações em que os radiologistas não estão disponíveis (por exemplo, países em desenvolvimento).

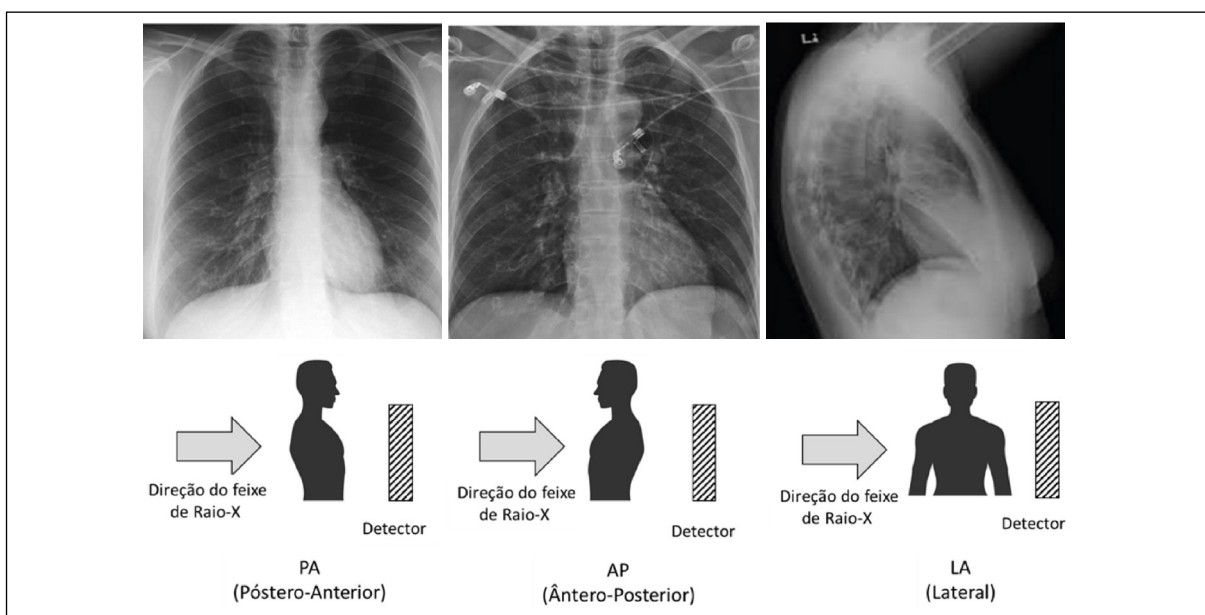
O processo diagnóstico a partir de imagens geralmente requer uma busca inicial por estruturas alvo (segmentação), quantificação de parâmetros e métricas (como tamanho, movimento, alteração de textura e deformação) para encontrar possíveis anormalidades. O campo da análise computadorizada de imagens médicas vem abordando esses problemas

desde a década de 1970. As técnicas de processamento, que inicialmente eram realizadas no nível do pixel (filtros para borda, crescimento de região, por exemplo), evoluíram rapidamente para modelagem matemática por sistemas baseados em regras.<sup>1</sup> Essas técnicas, embora possam ter funcionado muito bem para tarefas muito específicas, não são generalizáveis para uma ampla gama 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.<sup>3</sup> A transição dos sistemas baseados em modelo para sistemas que aprendem com os dados foi gradual inicialmente, 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.<sup>1</sup> 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.<sup>14</sup>

## APRENDIZADO PROFUNDO EM IMAGENS MÉDICAS

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<sup>15</sup> e o ADALINE.<sup>16</sup> 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 80, a partir da introdução do método de retro propagação para o treinamento de redes com camadas ocultas, proporcionou uma melhoria significativa na solução



**Figura 1.** Esquerda: radiografia de tórax em incidência Pósterio-Anterior (PA). Centro: radiografia de tórax em incidência ântero-Posterior (AP); Direita: radiografia de tórax Lateral (LA).

de problemas, especialmente no reconhecimento de padrões em várias áreas do conhecimento.<sup>17</sup> Entretanto, as aplicações na área de Ciência da Saúde eram ainda muito limitadas. No final do século passado, 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. As redes neurais profundas, conhecidas como de aprendizagem profunda, ou *deep learning*,<sup>18</sup> que surgiram no final da primeira década deste século, constituem a terceira onda. Entre estas redes, as redes neurais convolucionais (CNN) são as que têm um maior número de aplicações, por introduzirem 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 camada de amostragem - foi introduzida inspirada pelo processamento do córtex visual de mamíferos. Esta última 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, conferiram o poder computacional necessário à evolução tecnológica atual. A CNN foi considerada um dos dez maiores avanços tecnológicos do ano de 2013.<sup>19</sup>

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.

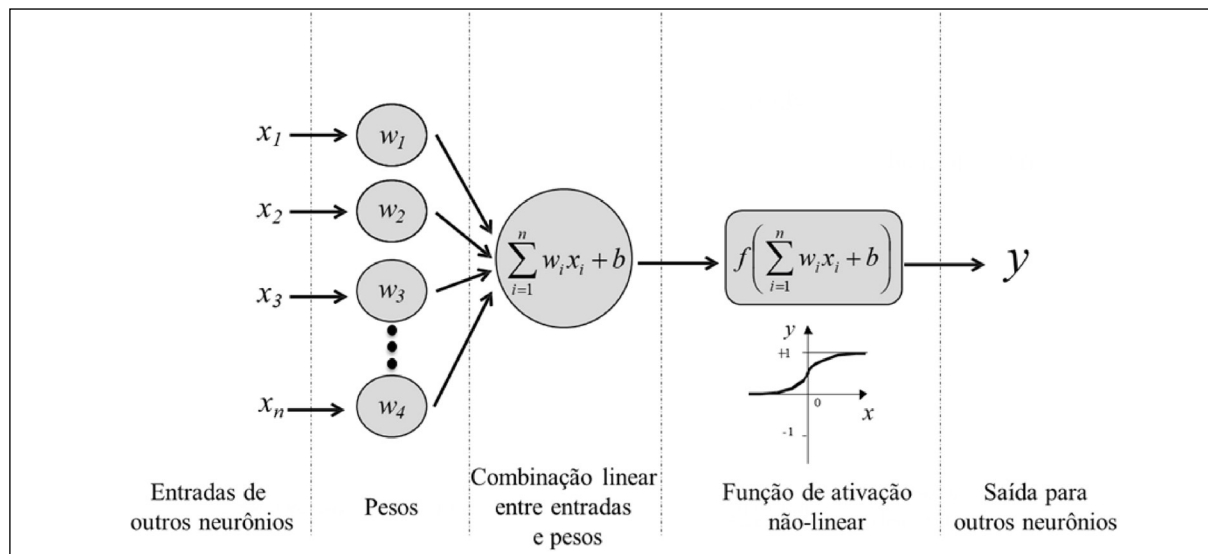
Nos últimos anos, o aprendizado profundo tornou-se a técnica de escolha para tarefas de análise de imagens e teve um tremendo impacto no campo da imagem médica.<sup>2</sup> O aprendizado profundo é notoriamente faminto por dados e a comunidade de pesquisa CXR se beneficiou da publicação de vários grandes bancos de dados rotulados nos últimos anos, predominantemente habilitados pela geração de rótulos por meio da análise automática de relatórios de radiologia. Essa tendência começou em 2017 com a liberação de 112.000 imagens do centro clínico do *National Institute of Health*, Estado Unidos.<sup>20</sup> Somente em 2019, mais de 755.000 imagens foram disponibilizadas em três bancos de dados rotulados: CheXpert,<sup>21</sup> MIMIC-CXR,<sup>22</sup> PadChest.<sup>23</sup>

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 limitados podem levar a decisões imprecisas.<sup>24</sup>

## REDES NEURAIS CONVOLUCIONAIS

As Rede Neurais Convolucionais, ou *Convolutional Neural Networks* (CNN), são um tipo especial de rede neural multicamadas inspiradas no mecanismo do sistema óptico dos seres vivos. Hubel e Wiesel descobriram que as células do córtex visual animal detectam luz no pequeno campo receptivo.<sup>25</sup> Motivado por este trabalho, em 1980, Kunihiko Fukushima introduziu o neocognitron<sup>26</sup> que é uma rede neural multicamadas capaz de reconhecer padrões visuais hierarquicamente, através da uma estratégia de aprendizagem profunda. Esta rede é considerada como a inspiração teórica para a CNN. Em 1998 LeCun et al., introduziram um modelo prático para CNN denominado LeNet-5<sup>27</sup> para reconhecimento de padrões visuais de pixels em imagens, com menos conexões e parâmetros do que em redes neurais convencionais, com tamanho de rede semelhante, facilitando o treinamento do modelo.

Em uma CNN, camadas são formadas por unidades básicas chamadas neurônios artificiais. O neurônio artificial é um modelo simplificado e simulado do neurônio real e suas



**Figura 2.** Modelo do neurônio artificial, para o qual  $x_1$  a  $x_n$  são as entradas de outros neurônios,  $w_1$  a  $w_n$  são os pesos para cada uma das entradas utilizados para a combinação linear e  $f$  é a função de ativação não-linear, neste caso a função sigmoide.



características básicas são a adaptação e a representação de conhecimentos baseadas em conexões. Cada neurônio recebe sinais dos neurônios da camada anterior e possui conexões ponderadas por pesos com os neurônios da camada posterior. A combinação linear dos sinais recebidos e pesos para cada sinal é utilizada como parâmetro de uma função de ativação, responsável por realizar uma transformação não-linear nesse valor. O resultado dessa função não-linear é emitido como sinal para a próxima camada. (Figura 2) A primeira camada é a única exceção na qual o sinal emitido é formado pelos dados iniciais, sem a aplicação de uma função de ativação.

Considerando o cenário de classificação, a intensidade do sinal de saída da última camada da CNN pode ser entendida como a quantidade de certeza de que um objeto pertença a determinada classe. Em treinamentos supervisionados, isto é, quando exemplos anotados são utilizados no treinamento, uma função de perda é usada para obter o erro de classificação da rede. Essa função deve ser projetada de tal maneira que sua minimização esteja relacionada com o aprendizado da rede. Durante o treinamento, o erro é usado para obter atualizações, que são propagadas pelos neurônios de forma semelhante à propagação dos sinais descrita, porém no sentido inverso (i.e., da camada de saída para a camada de entrada). As atualizações são calculadas como o negativo do gradiente da função de perda em relação a cada neurônio de saída e a propagação para as demais camadas é análoga à aplicação da regra da cadeia. Esse processo é chamado de retropropagação, ou *backpropagation*, e visa corrigir os pesos das conexões entre neurônios no sentido contrário ao gradiente, de modo a diminuir o erro, convergindo para um mínimo local ou global da função de perda. Uma vez que a função de perda representa o erro, sua minimização promove consequentemente o aprendizado da rede.

## Métodos de aprendizado profundo em imagens de raio-x de tórax

O treinamento de modelos de CNN depende da disponibilidade de grandes conjuntos de imagens devidamente anotadas por especialistas. A anotação é diferente de acordo com a tarefa computacional a ser realizada pela rede neural. Alguns dos principais tipos são: classificação, localização e segmentação. Na classificação as anotações consistem em um texto que indica quais classes ou doenças estão representadas em cada imagem. Um exemplo é a identificação de Cardiomegalia em imagens de CXR.

Para a localização, a anotação consiste em marcar dentro de cada imagem regiões de interesse, ou *region of interest* (ROI), e suas respectivas classes. Um exemplo é indicar com um retângulo a localização de nódulos pulmonares. Na segmentação, a anotação consiste em demarcar, pixel a pixel, qual a região de interesse, destacando um objeto. Um exemplo é a segmentação automática da região do pulmão.

Um outro fator importante para o treinamento bem-sucedido de uma rede neural é a disponibilidade de conjuntos de imagens diversificadas, isto é, imagens de diferentes sujeitos com idades variadas e diferentes fenótipos. Além disso, é interessante ter imagens advindas de diversos equipamentos de aquisição (por exemplo, diferentes fabricantes), com

diversas qualidades da imagem e diversos protocolos de aquisição. A diversificação durante o treino permite que a rede seja capaz de lidar com imagens nunca antes vistas mais facilmente, durante o uso no dia a dia. Após ter uma base de dados com essas características, o treinamento das CNNs consiste em fornecer pares <entrada, saída>, ou seja, <entrada=imagem N, saída = anotação N> para cada imagem e realizar um processo de atualização dos pesos da rede. Como resultado, a CNN aprende, a partir dos exemplos fornecidos, a reconhecer padrões e objetos dentro da imagem. Após o treinamento, aplica-se uma nova entrada (uma imagem nova, que não faz parte do conjunto de treino), a qual gera uma nova saída. Uma vez que a rede tenha sido bem treinada, deve corresponder a anotação correta da imagem.

Na literatura é possível encontrar centenas de artigos que utilizam métodos de aprendizado profundo em imagens de CXR para tarefas como:

## Classificação de imagens

A classificação de imagens de CXR é uma tarefa na qual uma CNN treinada fornece a probabilidade (predição) de uma imagem possuir características radiológicas associadas a uma doença específica (rótulo ou anotação).

Na literatura, este tipo de tarefa tem sido direcionada para prever se uma imagem de CXR tem achados relacionados a pneumonia,<sup>28,29</sup> pneumotórax,<sup>30,31</sup> cardiomegalia,<sup>32,33</sup> pneumonia associada a COVID,<sup>34,35</sup> entre outras doenças, ou se a imagem pertence a uma pessoa sem doença cardiopulmonar.<sup>36,37</sup> Em alguns estudos é possível ver como o uso das CNN é usado para definir a priorização no atendimento do paciente<sup>38</sup> e para definir o nível de comprometimento pulmonar dada uma doença específica.<sup>39</sup> Dependendo da doença é possível encontrar trabalhos com resultados comparáveis ao desempenho de especialistas.<sup>37,40,41</sup>

Segundo Hosmer, Lemeshow e Sturdivant,<sup>42</sup> um algoritmo com desempenho avaliado pela área sob a curva ROC (AUC) entre 0,7 e 0,8 pode ser considerado um algoritmo com poder discriminatório aceitável; entre 0,8 e 0,9 apresenta excelente poder de classificação e, acima de 0,9, são modelos com poder discriminatório excepcionais.

A Tabela 1 apresenta resultados recentes na literatura obtidos por diferentes métodos baseados em aprendizado profundo para a classificação de imagens CXR. Pode-se observar que, vários métodos apresentam desempenho com AUC superior a 0,81, indicando excelente poder de classificação.

## Localização de lesões

Com o aprimoramento das CNNs, surgiram as redes que atuam na detecção e localização de determinados objetos na imagem. O termo detecção de objetos em imagens é uma tarefa de visão computacional que visa localizar instâncias de objetos de determinada classe em uma imagem digital ou digitalizada. Em imagens médicas, por exemplo, esse tipo de rede pode ser usado na identificação de regiões anatômicas, áreas com anormalidade ou estruturas de objetos estranhos.

A identificação de uma região específica dentro da imagem é indicada por uma caixa delimitadora, que é formada pelas coordenadas extremas de um retângulo (pontos à esquerda, direita, superior e inferior). A cada previsão de localização

**Tabela 1.** Resultados obtidos por diferentes métodos baseados em aprendizado profundo para a classificação de imagens CXR em termos de acurácia (ACC), área sob a curva ROC (AUC), F1-Escore, Sensibilidade (Se) e Especificidade (Sp).

Autor	Doença	Base de dados	Número de Exames	Numero de casos positivos	ACC	AUC	F1-Escore	Se	Sp
Rajaraman et al., 2018	Pneumonia Pediátrica	Guangzhou	624	390	0,957	0,990	0,967	0,983	0,915
Ferreira et al., 2020	Pneumonia Pediátrica	Guangzhou	624	390	0,974	0,973	0,979	0,979	0,966
H Wang et al., 2020	pneumotórax	SIIM-ACR	1372	290	-	0,870	0,600	0,780	0,780
Q Wang et al., 2020	pneumotórax	Privada	2213	1083	0,935	-	0,930	0,886	0,981
Ferreira-Junior et al., 2021	Cardiomegalia	Padchest/Open/Privada	1800	341	-	0,828	-	0,927	0,729
Sogancioglu et al., 2021	Cardiomegalia	ChestX-ray14	400	200	-	0,978	-	0,970	0,900
Castiglioni et al., 2021	Covid	Hospitais em Lombardia (Italia)	110	74	-	0,810	-	0,800	0,810
Rajaraman et al., 2020	Covid	Múltiplas fontes	144	72	0,910	0,951	0,909	0,903	0,945
Hwang et al., 2019	Anormal	Privada	1089	789	-	0,965	-	0,951	0,750
Tang et al., 2020	Anormal	Múltiplas fontes	1344	653	0,924	0,984	0,925	0,971	0,880

fornecida pelo sistema, é associado um valor, que varia entre zero e um, o qual indica a confiabilidade do sistema, ou *confidence score*, de que a caixa delimitadora descreve corretamente o objeto da classe que se deseja detectar.

Para avaliar a concordância entre as anotações do especialista e as previsões do sistema, ambas as caixas delimitadoras são comparadas de acordo com uma métrica de similaridade. Caso a comparação não resulte em um valor mínimo de similaridade, considera-se que a localização não corresponde ao objeto da classe detectada, ou seja, ocorreu uma falsa detecção. Se mais de uma previsão obtiver similaridade acima do valor mínimo em relação a anotação de referência, considera-se que ocorreram detecções repetidas.<sup>43</sup> É possível suprimir as caixas delimitadoras por meio da união das repetidas ou daquelas com baixa pontuação de confiança. A Figura 3 representa essa “supressão”, onde em Figura 3a exibe as previsões para anormalidades na região torácica com pontuação de confiança de 0,05. Em Figura 3b, caixas delimitadoras com determinada razão de sobreposição são removidas. Já em Figura 3c tem-se a eliminação das caixas delimitadoras com pontuação de confiança inferior a 0,2.<sup>44</sup>

Um sistema simples indicando a caixa delimitadora de regiões anormais pode ajudar no direcionamento da atenção do radiologista, apresentando potencial para aumentar a sensibilidade para achados sutis ou que estejam em regiões de difícil visualização devido a sobreposição de estruturas. Além disso, a determinação de regiões anormais (pneumonia, tuberculose, nódulos), anatomia (costelas), ou de objetos (cateter) via caixa delimitadora pode ser mais fácil de se alcançar que a segmentação precisa da região. Isso pode ser atribuído à dificuldade de anotação precisa na imagem de projeção e ao alto custo de tempo que essa operação demandaria do radiologista.<sup>45</sup> A Figura 4 ilustra alguns exemplos de previsões bem sucedidas na localização de regiões de opacidade pulmonar.<sup>44</sup>

Um desafio na construção de sistemas robustos de localização por meio de aprendizado profundo está na coleta de um grande conjunto de dados anotados. A coleta de tais anotações é demorada e dispendiosa. Muitos conjuntos de dados públicos fornecem imagens com qualidade inferior à

utilizada para leitura radiológica na clínica. Isso pode ocasionar uma diminuição no desempenho desses sistemas, principalmente para anormalidades sutis. A redução da qualidade geralmente está relacionada a uma diminuição na resolução espacial ou na profundidade da imagem. Isso é realizado para reduzir o tamanho geral do conjunto de dados, de modo a se reduzir o esforço computacional. Em outros casos, as imagens de CXR foram coletadas através da captura de telas da literatura online, resultando em uma degradação não quantificável dos dados. Além disso, pode haver um pré-processamento antes da disponibilização dos dados e o mesmo não ser descrito.<sup>45</sup>


### Exemplo de aplicação

Imagens de CXR são produzidas em grande volume devido ao seu baixo custo e variada capacidade diagnóstica. Porém, nem sempre existem radiologistas suficientes para rever rapidamente todas as imagens produzidas durante o atendimento. Dessa maneira, é possível que exames prioritários sejam postergados devido ao volume de atendimento, prejudicando a atenção ao paciente. Nesse contexto, uma aplicação que auxilie o radiologista a priorizar a fila de atendimento de exames de CXR, classificando as imagens de acordo com um critério de prioridade, pode otimizar o fluxo de atendimento.


Além disso, é preciso que o algoritmo de priorização esteja incluído no fluxo de atendimento do hospital ou clínica, de forma que, à medida que os exames sejam realizados, seja também criada a fila de atendimento.

Nesse sentido, as soluções envolvendo aprendizado de máquina para a classificação automática de CXR para fins de triagem necessitam estarem integradas aos sistemas de armazenamento e transmissão de imagens médicas, ou “Picture, Archiving and Communication System” (PACS), de modo que possam ser incorporados à rotina da área de Radiologia.

Atualmente, no Instituto do Coração do Hospital das Clínicas de Universidade de São Paulo, há um esforço para o desenvolvimento de um sistema de classificação de imagens CXR, denominado XR<sub>AI</sub>, que está totalmente integrado ao PACS da Instituição. Os exames nessa modalidade são



**Figura 3.** (A) Previsão de regiões potencialmente suspeitas em uma radiografia de tórax com pontuação de confiança (0,05); (B) pontuação de confiança de 0,05, porém com a supressão de caixas delimitadoras com uma dada sobreposição; e (C) com pontuação de confiança de 0,2.



**Figura 4.** Dados experimentais de previsões de um modelo localizador de regiões de opacidade pulmonar e o respectivo ground truth (GT), as quais estão mostradas como sobreposições verdes e azuis, respectivamente.

filtrados, selecionando-se somente os exames de CXR, que sejam do tipo PA e de pacientes maiores que 16 anos. O critério de idade é utilizado pois a rede neural foi treinada somente com dados de adultos, o que levaria a erros de classificação em exames nunca antes vistos. Isso reforça a importância da existência de bases de dados anotadas e curadas que representam adequadamente a população no qual a rede neural será aplicada.

A partir das imagens coletadas do PACS, uma rede neural convolucional classifica as imagens em: “sem achados” e “com achados”. Entre as imagens com achados, é feito um refinamento para a classificação de “opacidade”. As sub-classificações estão sendo refinadas para incluir outras patologias como alongamento de aorta, cardiomegalia e outras (imagens identificadas como anormais, mas cuja patologia não pode ser definida pela rede neural).

O resultado do processamento pode ser exibido na forma de uma página web, que cicla continuamente sobre a lista de pacientes da fila de atendimento, mostrando o exame de raios-x à esquerda, e, à direita, os dados anonimizados do paciente, junto com a classificação atribuída pela rede neural (Figura 5).

A classificação da urgência é dada por um valor arbitrário, variando entre zero e cem, que determina a ordem na lista apresentada na interface web. Assim, uma imagem sem achados tem valor 20, enquanto que uma imagem anormal tem valor 50 e uma imagem anormal e com opacidades tem valor 70. Este valor foi estabelecido ad-hoc e pode ser alterado de acordo com o critério desejado e as classes existentes, de acordo com a criticidade para a exibição dos dados.

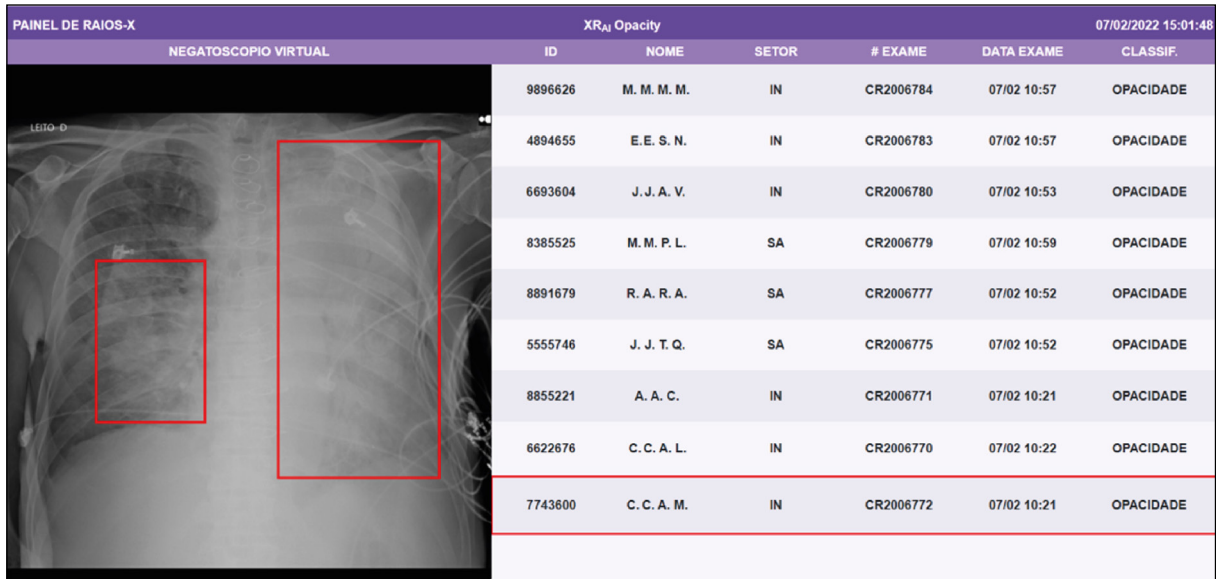
## CONCLUSÕES

Atualmente, há um grande esforço voltado para a proposição de técnicas de aprendizado profundo em todos os campos da radiologia. A radiologia de tórax é uma das modalidades de imagem mais econômicas e tem coletado uma enorme quantidade de dados ao longo dos anos. Paralelamente, com a crescente publicação de vários conjuntos de dados, contendo dezenas de milhares de imagens de raios-X de tórax, possibilitou e flexibilizou a exploração de novos métodos de aprendizado profundo em radiologia.

Entretanto, esses avanços não visam substituir o radiologista, mas sim oferecer uma ferramenta de apoio para auxiliar no diagnóstico. Mesmo que o aprendizado de máquina seja capaz de alcançar a automação total em radiologia, a validação humana sempre será necessária.

A breve revisão neste artigo demonstra que as redes neurais convolucionais possuem capacidade de classificar, segmentar e localizar lesões em imagens CXR com excelente desempenho. Em muitos casos, esses algoritmos são modelos com poder discriminatório excepcional. Entretanto, tais arquiteturas dependem de uma estratégia de treinamento e de grandes volumes de dados, os quais são aspectos críticos em aprendizado de máquina.

Alguns dos estudos mencionados nesta revisão mostraram resultados exemplares quando o treinamento e o teste dos algoritmos ocorreram sempre na mesma base de dados de imagens. Esses resultados podem ser influenciados pelo conjunto de treinamento e podem ser questionados em termos de precisão e reprodutibilidade, pois não foram testados em diferentes bancos de dados de imagens.



**Figura 5.** Exemplo de protótipo de aplicação que reconhece opacidade em imagens de raios-X PA, vinculado ao sistema PACS do hospital (dados de paciente anonimizados).

Com o crescente número de bancos de dados de imagens de código aberto agora disponíveis, os algoritmos podem ser expostos a mais imagens anotadas por diferentes radiologistas. Embora muitos conjuntos de dados estejam abertos para uso público, apenas alguns deles são anotados por radiologistas especialistas.

Os trabalhos futuros para classificação automática de imagens de radiografia de tórax, utilizando aprendizado profundo, devem ter um foco nas necessidades clínicas envolvendo a interpretação de imagens CXR. A comparação do desempenho e a precisão desses algoritmos devem ser estimulados por meio de novos desafios públicos, utilizando-se de dados anotados apropriadamente para tarefas clinicamente relevantes.

## AGRADECIMENTOS

Este trabalho foi apoiado pela Foxconn Brasil e Fundação Zerbini como parte do projeto de pesquisa “Aprendizado de Máquina em Medicina Cardiovascular”.

## CONFLITOS DE INTERESSE

Os autores declaram não possuir conflitos de interesse na realização deste trabalho.

## REFERÊNCIAS

- Greenspan H, Ginneken B van, Summers RM. Guest Editorial Deep Learning in Medical Imaging: Overview and Future Promise of an Exciting New Technique. *IEEE Trans Med Imaging*. 2016;35(5):1153–9.
- Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Med Image Anal*. 2017;42:60–88. Available from: <http://www.sciencedirect.com/science/article/pii/S1361841517301135>
- Shen D, Wu G, Suk H-I. Deep Learning in Medical Image Analysis. *Annu Rev Biomed Eng*. 2017;19(1):221–48. Available from: <https://doi.org/10.1146/annurev-bioeng-071516-044442>
- United Nations. United Nations scientific committee on the effects of atomic radiation (UNSCEAR), 2008 report on sources and effects of ionizing radiation. 2008. Available from: [http://www.unscear.org/docs/publications/2008/UNSCEAR\\_2008\\_Annex-A-CORR.pdf](http://www.unscear.org/docs/publications/2008/UNSCEAR_2008_Annex-A-CORR.pdf)
- Mettler FA, Bhargavan M, Faulkner K, Gilley DB, Gray JE, Ibbott GS, et al. Radiologic and Nuclear Medicine Studies in the United States and Worldwide: Frequency, Radiation Dose, and Comparison with Other Radiation Sources—1950–2007. *Radiology*. 2009;253(2):520–31. Available from: <https://doi.org/10.1148/radiol.2532082010>
- Raouf S, Feigin D, Sung A, Raouf S, Irugulapati L, Rosenow EC. Interpretation of Plain Chest Roentgenogram. *Chest*. 2012;141(2):545–58. Available from: <https://www.sciencedirect.com/science/article/pii/S0012369212600968>
- Quekel LGBA, Kessels AGH, Goei R, van Engelshoven JMA. Detection of lung cancer on the chest radiograph: a study on observer performance. *Eur J Radiol*. 2001;39(2):111–6. Available from: <https://www.sciencedirect.com/science/article/pii/S0720048X01003011>
- Balabanova Y, Coker R, Fedorin I, Zakharova S, Plavinskij S, Krukov N, et al. Variability in interpretation of chest radiographs among Russian clinicians and implications for screening programmes: observational study. *BMJ*. 2005;331(7513):379–82. Available from: <http://www.bmj.com/content/331/7513/379.abstract>
- Young M, Marrie TJ. Interobserver Variability in the Interpretation of Chest Roentgenograms of Patients With Possible Pneumonia. *Arch Intern Med*. 1994;154(23):2729–32. Available from: <https://doi.org/10.1001/archinte.1994.00420230122014>
- Lodwick GS, Keats TE, Dorst JP. The Coding of Roentgen Images for Computer Analysis as Applied to Lung Cancer. *Radiology*. 1963;81(2):185–200. Available from: <https://doi.org/10.1148/81.2.185>
- Becker HC, Nettleton WJ, Meyers PH, Sweeney JW, Nice CM. Digital Computer Determination of a Medical Diagnostic Index Directly from Chest X-Ray Images. *IEEE Trans Biomed Eng*. 1964;11(3):67–72.
- Kruger RP, Townes JR, Hall DL, Dwyer SJ, Lodwick GS. Automated Radiographic Diagnosis via Feature Extraction and Classification of Cardiac Size and Shape Descriptors. *IEEE Trans Biomed Eng*. 1972;19(3):174–86.
- Toriwaki J-I, Suenaga Y, Negoro T, Fukumura T. Pattern recognition of

chest X-ray images. *Comput Graph Image Process*. 1973;2(3):252–71. Available from: <https://www.sciencedirect.com/science/article/pii/0146664X73900051>

14. Wainberg M, Merico D, Delong A, Frey BJ. Deep learning in biomedicine. *Nat Biotechnol* [Internet]. 2018 Sep 6;36:829. Available from: <https://doi.org/10.1038/nbt.4233>
15. Rosenblatt F. The perceptron: A probabilistic model for information storage and organization in the brain. Vol. 65. *Psychological Review*. US: American Psychological Association. 1958;386–408.
16. Widrow B, Hoff ME. Associative Storage and Retrieval of Digital Information in Networks of Adaptive “Neurons” BT - Biological Prototypes and Synthetic Systems: Vol 1. Proceedings of the Second Annual Bionics Symposium sponsored by Cornell University and the General Elect. In: Bernard EE, Kare MR, editors. Boston, MA: Springer US. 1962;160. Available from: [https://doi.org/10.1007/978-1-4684-1716-6\\_25](https://doi.org/10.1007/978-1-4684-1716-6_25)
17. Leung H, Haykin S. The complex backpropagation algorithm. *IEEE Trans Signal Process*. 1991;39(9):2101–4.
18. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521(7553):436–44. Available from: <https://doi.org/10.1038/nature14539>
19. Hof RD. The 10 Breakthrough Technologies of 2013: Deep Learning. 2013. Available from: <https://www.technologyreview.com/s/513696/deep-learning/>
20. Wang X, Peng Y, Lu L, Lu Z, Bagheri M, Summers RM. ChestX-Ray8: Hospital-Scale Chest X-Ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases. In: 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2017; 3462–71.
21. Irvin J, Rajpurkar P, Ko M, Yu Y, Ciurea-Illcus S, Chute C, et al. CheXpert: A Large Chest Radiograph Dataset with Uncertainty Labels and Expert Comparison. *Proc AAAI Conf Artif Intell*. 2019;33(1):590–7. Available from: <https://ojs.aaai.org/index.php/AAAI/article/view/3834>
22. Johnson AEW, Pollard TJ, Berkowitz SJ, Greenbaum NR, Lungren MP, Deng C, et al. MIMIC-CXR, a de-identified publicly available database of chest radiographs with free-text reports. *Sci Data*. 2019;6(1):317. Available from: <https://doi.org/10.1038/s41597-019-0322-0>
23. Bustos A, Pertusa A, Salinas J-M, de la Iglesia-Vayá M. PadChest: A large chest x-ray image dataset with multi-label annotated reports. *Med Image Anal*. 2020;66:101797. Available from: <https://www.sciencedirect.com/science/article/pii/S1361841520301614>
24. Krittanawong C, Zhang H, Wang Z, Aydar M, Kitai T. Artificial Intelligence in Precision Cardiovascular Medicine. *J Am Coll Cardiol*. 2017;69(21):2657–64. Available from: <http://www.onlinejacc.org/content/69/21/2657.abstract>
25. Hubel DH, Wiesel TN. Receptive fields and functional architecture of monkey striate cortex. *J Physiol*. 1968;195(1):215–43. Available from: <https://doi.org/10.1113/jphysiol.1968.sp008455>
26. Fukushima K, Miyake S. Neocognitron: A Self-Organizing Neural Network Model for a Mechanism of Visual Pattern Recognition BT - Competition and Cooperation in Neural Nets. In: Amari S, Arbib MA, editors. Berlin, Heidelberg: Springer Berlin Heidelberg. 1982;267–85.
27. Lecun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. *Proc IEEE*. 1998;86(11):2278–324.
28. Rajaraman S, Candemir S, Kim I, Thoma G, Antani S. Visualization and Interpretation of Convolutional Neural Network Predictions in Detecting Pneumonia in Pediatric Chest Radiographs. *Appl Sci*. 2018;8(10):1715.
29. Ferreira JR, Cardenas DAC, Moreno RA, Rebelo MFS, Krieger JE, Gutierrez MA. Multi-View Ensemble Convolutional Neural Network to Improve Classification of Pneumonia in Low Contrast Chest X-Ray Images. In: 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). IEEE. 2020;1238–41.
30. Wang H, Gu H, Qin P, Wang J. CheXLocNet: Automatic localization of pneumothorax in chest radiographs using deep convolutional neural networks. Xie H, editor. *PLoS One*. 2020;15(11):e0242013.
31. Wang Q, Liu Q, Luo G, Liu Z, Huang J, Zhou Y, et al. Automated segmentation and diagnosis of pneumothorax on chest X-rays with fully convolutional multi-scale ScSE-DenseNet: a retrospective study. *BMC Med Inform Decis Mak*. 2020;20(S14):317.
32. Sogancioglu E, Murphy K, Calli E, Scholten ET, Schalekamp S, van Ginneken B. Cardiomegaly Detection on Chest Radiographs: Segmentation Versus Classification. *IEEE Access*. 2020;8:94631–42.
33. Ferreira-Junior J, Cardenas D, Moreno R, Rebelo M, Krieger J, Gutierrez M. A general fully automated deep-learning method to detect cardiomegaly in chest x-rays. In: Drukker K, Mazurowski MA, editors. *Medical Imaging 2021: Computer-Aided Diagnosis*. SPIE; 2021;81.
34. Rajaraman S, Sornapudi S, Alderson PO, Folio LR, Antani SK. Analyzing inter-reader variability affecting deep ensemble learning for COVID-19 detection in chest radiographs. Huo Y, editor. *PLoS One*. 2020;15(11):e0242301.
35. Castiglioni I, Ippolito D, Interlenghi M, Monti CB, Salvatore C, Schiaffino S, et al. Machine learning applied on chest x-ray can aid in the diagnosis of COVID-19: a first experience from Lombardy, Italy. *Eur Radiol Exp*. 2021;5(1):7.
36. Tang Y-X, Tang Y-B, Peng Y, Yan K, Bagheri M, Redd BA, et al. Automated abnormality classification of chest radiographs using deep convolutional neural networks. *npj Digit Med*. 2020;3(1):70.
37. Hwang EJ, Park S, Jin K-N, Kim JI, Choi SY, Lee JH, et al. Development and Validation of a Deep Learning–Based Automated Detection Algorithm for Major Thoracic Diseases on Chest Radiographs. *JAMA Netw Open*. 2019;2(3):e191095.
38. Annarumma M, Withey SJ, Bakewell RJ, Pesce E, Goh V, Montana G. Automated Triage of Adult Chest Radiographs with Deep Artificial Neural Networks. *Radiology*. 2019;291(1):196–202.
39. Cohen JP, Dao L, Roth K, Morrison P, Bengio Y, Abbasi AF, et al. Predicting COVID-19 Pneumonia Severity on Chest X-ray With Deep Learning. *Cureus*. 2020;12(7):e9448.
40. Rajpurkar P, O’Connell C, Schechter A, Asnani N, Li J, Kiani A, et al. CheXaid: deep learning assistance for physician diagnosis of tuberculosis using chest x-rays in patients with HIV. *npj Digit Med*. 2020;3(1):115.
41. Rajpurkar P, Irvin J, Ball RL, Zhu K, Yang B, Mehta H, et al. Deep learning for chest radiograph diagnosis: A retrospective comparison of the CheXNeXt algorithm to practicing radiologists. *PLoS Med*. 2018;15(11):e1002686.
42. Jr. Hosmer DW, Lemeshow S, Sturdivant RX. *Applied Logistic Regression*. 3rd. ed. Hoboken, New Jersey: John Wiley & Sons, Inc. 2013.
43. Silva GR. Detecção de objetos em imagens utilizando técnicas de aprendizagem profunda. Universidade Federal de Santa Catarina; 2018.
44. Marcomini KD, Cardenas DAC, Traina AJM, Gutierrez MA. A deep learning approach for COVID-19 screening and localization on Chest X-Ray images. In: Proceedings of SPIE Medical Imaging. 2022.
45. Çalli E, Sogancioglu E, van Ginneken B, van Leeuwen KG, Murphy K. Deep learning for chest X-ray analysis: A survey. *Med Image Anal*. 2021;72:102125.

# APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL EM IMAGEM CARDIOVASCULAR: EM ECOCARDIOGRAFIA

## APPLICATION OF ARTIFICIAL INTELLIGENCE IN CARDIOVASCULAR IMAGING : IN ECHOCARDIOGRAPHY



Clique para acessar  
o Podcast

Edgar Daminello<sup>1</sup>  
Paulo Pinto Alves Campos  
Vieira<sup>2</sup>  
Cláudio Henrique Fischer<sup>1,3</sup>  
Marcelo Luiz Campos  
Vieira<sup>1,4</sup>

1. Hospital Israelita Albert Einstein. São Paulo, SP, Brasil.
2. Universidade Santo Amaro (UNISA). São Paulo, SP, Brasil.
3. Universidade Federal de São Paulo (UNIFESP). São Paulo, SP, Brasil.
4. Instituto do Coração (InCor). Faculdade de Medicina da Universidade de São Paulo (FMUSP). São Paulo, SP, Brasil.

Correspondência:  
Marcelo Luiz Campos Vieira  
mluiz766@terra.com.br

### RESUMO

Inteligência artificial (IA) é a capacidade de dispositivos eletrônicos de tomar decisões e resolver problemas por meio de algoritmos sem a interferência humana. O aprendizado de máquina e o aprendizado profundo são técnicas que servem de base para a maioria das funções da IA. Seu emprego pode tornar a ecocardiografia mais eficiente, fazendo-a menos dependente do observador e com menor tempo de aquisição dos exames. Por meio de algoritmos, a aquisição de imagens cardíacas torna-se mais fácil, rápida e precisa, reduzindo assim a variabilidade inter e intraobservador e auxiliando a interpretação de dados complexos. Além da aquisição e interpretação das imagens, a IA tem aplicação no desenvolvimento de relatórios e laudos, e a tecnologia tem sido usada no acompanhamento da evolução dos pacientes. Recursos de medição automática, incluindo a determinação da fração de ejeção do ventrículo esquerdo, dimensões das câmaras cardíacas, espessura da parede e medidas de Doppler já foram validados em ambiente clínico. A avaliação da segmentação valvar, importante na intervenção cardíaca estrutural minimamente invasiva e por catéteres, é outra área em expansão. O futuro da IA na ecocardiografia está na análise automatizada de dados clínicos e de imagem para o melhor diagnóstico de diversas cardiopatias, assim como para a prevenção dos resultados terapêuticos e dos riscos individuais. As limitações da implementação da IA são dados de entrada de má qualidade ou enviesados, padrões não uniformes entre os fornecedores e a necessidade de integração entre os diferentes algoritmos para que funcionem em equipamentos diversos.

**Descritores:** Inteligência Artificial; diagnóstico automatizado, algoritmo, Ecocardiografia; quantificação cardíaca

### ABSTRACT

*Artificial intelligence (AI) is the ability of electronic devices to make decisions and solve problems without human interference through algorithms. Machine learning and deep learning are techniques that underpin most AI functions. The use of AI can make echocardiography more efficient, less dependent on the observer, and result in shorter acquisition time. Using algorithms, the acquisition of cardiac images becomes easier, faster, and more accurate, thus reducing inter- and intra-observer variability and helping to interpret complex data. In addition to the acquisition and interpretation of images, AI has been applied to the development of reports and follow-up of patient progress. Automatic measurement capabilities, including determination of the left ventricular ejection fraction, cardiac chamber dimensions, wall thickness, and Doppler measurements, have already been validated. The evaluation of valve segmentation, important in minimally invasive and catheter-based structural cardiac intervention, is another expanding area. The future of AI in echocardiography lies in the automated analysis of clinical and image data for a better diagnosis of different heart diseases, as well as for the prevention of therapeutic results and individual risks. Limitations of the implementation of AI are poor quality or biased input data, non-uniform standards across vendors, and the need for integration between different algorithms so they work on different devices.*

**Keywords:** Artificial Intelligence; automated diagnosis, algorithm, Echocardiography; cardiac quantification.

## INTRODUÇÃO

A ecocardiografia quando comparada com outras modalidades de imagem cardiovascular como a tomografia computadorizada, a medicina nuclear e a ressonância magnética, é a única técnica que permite a análise em tempo real do coração, entretanto, é aquela que apresenta maior dependência da experiência do médico durante a aquisição e interpretação das imagens.<sup>1</sup> Nos últimos anos, ocorreu aumento expressivo na demanda e na complexidade dos exames ecocardiográficos, em virtude do avanço tecnológico, como: a análise da deformação miocárdica pela técnica ecocardiográfica de *speckle-tracking*; o desenvolvimento de programas de análise semiautomática de estruturas anatomicamente complexas como a valva mitral e o ventrículo direito; o surgimento da ecocardiografia tridimensional e a sua participação em procedimentos percutâneos invasivos como a oclusão de defeitos do septo atrial fechamento do apêndice atrial esquerdo e de *leaks* paraprotéticos e o implante percutâneo de valva aórtica (TAVI); e do tratamento da insuficiência mitral com dispositivos como MitraClip.<sup>2</sup> A Ecocardiografia no século 21 é o resultado da aplicação de conceitos físicos e matemáticos que permitem a aplicação da nanotecnologia, da tecnologia digital e da análise multiplanar tridimensional espacial das estruturas cardíacas em tempo real de forma acurada, reproduzível e rápida em diferentes situações clínicas.<sup>3-14</sup>

A aplicação da tecnologia da inteligência artificial em imagens cardiovasculares tornou-se relevante nos últimos anos, pois pôde reduzir o custo de tratamentos e evitar testes clínicos desnecessários.<sup>15</sup> A sua aplicação na área ecocardiográfica tem demonstrado potencial para resolver problemas como a necessidade de treinamento médico especializado, subjetividade do médico operador, amplas faixas de observação e distinções entre observadores e análises complexas. Assim, a IA é uma ferramenta que pode oferecer soluções para tornar a ecocardiografia mais eficiente, menos dependente do observador e com menor tempo de aquisição dos exames. Ela permite a análise de grande volume de dados (*big data*), que apresentam como características importantes o grande volume de informações, a sua aleatoriedade (grande variação) e a alta velocidade na sua possibilidade de ocorrência, necessitando de instrumentos de análise com grande acurácia e emprego de mecanismos matemáticos integrativos.

A integração da ecocardiografia e a IA já ocorre há certo tempo, remontando desde 1978, quando por meio da análise de Fourier, ela que avaliava a forma de onda do movimento das cúspides da valva mitral, ao modo M do ultrassom, no diagnóstico auxiliar do prolapso valvar mitral.<sup>16</sup> Em 2000, a obtenção da fração de fração tridimensional do ventrículo esquerdo necessitava de cerca de três a quatro horas de análise computacional. Atualmente essa análise, feita de forma mais acurada, é obtida com o emprego da inteligência artificial (IA) em menos de 60 segundos. Desde 2006, o uso da IA foi proposto na avaliação ecocardiográfica da função ventricular esquerda e na otimização da imagem e reconhecimento estrutural por meio da tecnologia de rastreamento semiautomático de marcas ultrassonográficas e do método de Simpson.<sup>17</sup>

Esta publicação descreve as vantagens da ecocardiografia integrada à IA, suas limitações e perspectivas futuras para o uso da tecnologia.

## CONCEITOS SOBRE INTELIGÊNCIA ARTIFICIAL

IA é a capacidade de dispositivos eletrônicos de coletar variáveis, analisar problemas e tomar decisões sem a interferência humana, por meio do desenvolvimento de algoritmos, isto é, sequências de instruções que orientam o funcionamento de um *software* de uma máquina.<sup>18</sup> Termos como Aprendizado de Máquina (AM, *learning machine*) e Aprendizado Profundo (AP, *deep learning*) são técnicas que servem de base para a maioria das funções da IA.

O AM usa métodos estatísticos que permitem a um computador utilizar os dados de entrada, aprender com eles e aprimorar o seu conhecimento sobre como reagir na próxima vez que receber dados semelhantes.<sup>1</sup> É a capacidade de aprender e melhorar o desempenho a partir da experiência. Ele é classificado em três grupos de aprendizado: supervisionado, não supervisionado e por reforço.<sup>1</sup> No supervisionado, a máquina é treinada a reconhecer padrões a partir de resultados conhecidos, é quando apresentamos ao algoritmo os dados de entrada e as respectivas saídas; no não supervisionado os dados de entrada são classificados em grupos com base nas semelhanças, apresentamos somente os dados de entrada e o algoritmo descobre as saídas; e, na aprendizagem por reforço, a máquina é treinada a tomar decisões por meio de tentativas e erros a fim de encontrar a uma solução ao problema. Exemplo: em seu uso na ecocardiografia, o AM representa a capacidade de identificar estruturas dentro de uma imagem e rotulá-las com precisão. Outro exemplo é a capacidade de determinar a fração de ejeção (FE) do ventrículo esquerdo (VE) após a análise de milhares de imagens com frações de ejeção previamente coletadas e conhecidas.

O AP é um subconjunto do AM, formado por uma centena de camadas de redes neurais artificiais, e é usado em situações em que uma grande quantidade de informações deve ser processada, permitindo que a máquina possa fazer previsões a partir de grandes conjuntos de dados.<sup>1,18</sup> Na ecocardiografia podemos observar sua utilização na capacidade do equipamento de reconhecer padrões de imagens ecocardiográficas de pacientes rotulados com cardiomiopatia hipertrófica e assim prever esta entidade a partir de novas imagens.

## APLICAÇÕES DA INTELIGÊNCIA ARTIFICIAL NA ECOCARDIOGRAFIA

### Aquisição e interpretação das imagens

Uma correta interpretação da ecocardiográfica consiste em dizer que o ofício se trata da análise de vários vídeos e imagens estáticas; tendo em vista que a estrutura e a função cardíacas são complexas e requerem muitas visualizações, as chamadas “janelas” ou planos ecocardiográficos de visualização.<sup>19</sup> Na aquisição destas “janelas”, mínimas angulações do feixe de ultrassom, podem promover dificuldades em fornecer uma análise precisa. De regra, o ecocardiografista é treinado por um a dois anos para obter a compreensão dos princípios básicos da ecocardiografia e habilidade para interpretá-los. A IA torna mais fácil a aquisição de imagens cardíacas, de forma mais rápida e precisa, inclusive na orientação de profissionais iniciantes, durante a

obtenção de imagens diagnósticas, reconhecendo visualizações incorretas, fornecendo orientação sobre como mover o transdutor para obter imagens mais adequadas.<sup>18,19</sup> Ela tem o potencial de superar as limitações humanas de fadiga e distração, minimizar a variabilidade inter e intraobservador e auxiliar na interpretação de dados complexos.<sup>18-20</sup>

Com o processo de interpretação das imagens mais preciso e reprodutível, há economia de tempo e permite a incorporação de dados atualmente não utilizados na avaliação geral para fornecer um diagnóstico mais exato. Após o treinamento, o algoritmo da IA é capaz de reconhecer diferentes padrões estruturais e funcionais cardíacos que, quando sutis, podem ser perdidos ao longo da interpretação pelo médico.<sup>19,20</sup>

## Otimização da confecção dos laudos ecocardiográficos e acompanhamento evolutivo

As aplicações da IA não se limitam a aquisição e interpretação das imagens, mas também relacionam-se ao desenvolvimento de laudo ou relatório e ao acompanhamento evolutivo do paciente.<sup>21,22</sup> Por meio da rápida avaliação dos ecocardiogramas, ela oferece o potencial de economizar o tempo dos profissionais de saúde que de outra forma teriam que realizar manualmente inúmeras medidas e gerar um laudo de seus achados. Como o número de ecocardiogramas realizados em todo o mundo está aumentando, essa tecnologia permitiria um aumento na varredura de dados, sem o aumento concomitante no tempo de relatório que, de outra forma, limitaria sua capacidade de examinar outros pacientes.<sup>23,24</sup> Essa avaliação rápida e precisa também pode ter benefícios que vão além do ambiente de Cardiologia, como o do Departamento de Emergência, no qual exames de ultrassom no local de atendimento estão se tornando cada vez mais comuns. Ao incorporar algoritmos de AM às práticas do dia a dia, existe o potencial de melhorar a precisão e a rapidez do diagnóstico ecocardiográfico no cenário agudo.<sup>1,25-28</sup>

## Avaliação da função ventricular e atrial

A avaliação funcional do VE é um dos procedimentos mais importantes e rotineiros de um exame ecocardiográfico e inclui a determinação dos volumes, FE, grau de espessamento sistólico das paredes e da sua deformação longitudinal (*strain*), massa ventricular esquerda entre outros índices. Estas avaliações baseiam-se na determinação manual de rastreamento endocárdico e na experiência clínica e vivência do médico com a ecocardiografia.<sup>25-28</sup>

A IA demonstrou fornecer inúmeros benefícios para o campo da ecocardiografia, permitindo a incorporação de dados atualmente não utilizados na avaliação geral da função cardíaca. Recursos de medição automatizada, incluindo a determinação da FE do VE, dimensões das câmaras, espessura da parede e medidas de Doppler já foram validados. Wang et al.,<sup>25</sup> utilizando-se da ressonância magnética (RM) demonstraram que há grande correlação entre o AP e profissionais experientes na determinação da FE e da massa do VE, inclusive na capacidade de prever eventos cardiovasculares adversos; entretanto, na decisão sobre a tomada de tratamentos, ainda há limitações. Atualmente,

existem vários *softwares* comerciais que podem promover medidas de ecocardiografia bi e tridimensional de alta precisão, que realizam uma avançada avaliação da função cardíaca esquerda. Estudos clínicos mostram que estes *softwares* automáticos podem fornecer acurácia semelhante aos métodos manuais, imitando médicos experientes ao traçar as bordas endocárdicas e calculando os volumes ventriculares. A IA pode ajudar a identificar melhor a borda apical do VE, o tempo dos eventos cardíacos, rastrear o miocárdico e medir o *strain* miocárdico em segundos.<sup>16</sup> Outros autores,<sup>21</sup> comparando a quantificação da massa do VE pelo ecocardiograma tridimensional, RM e um algoritmo de AM, demonstraram que este último é factível, rápido e acurado, reduzindo o tempo de realização do exame e viabilidade da sua incorporação na prática clínica.<sup>22</sup>

Em comparação com a análise do VE, a segmentação do ventrículo direito (VD) apresenta maior dificuldade, relacionado a sua complexa estrutura e anatomia (trabeculação miocárdica, formato irregular e parede mais fina).<sup>12</sup> A aplicabilidade da IA na avaliação do VD inclui a captura dos seus diâmetros, espessura, volume e alterações da área fracional entre outros indicadores, com maior rapidez e eficiência, por ora, entretanto, há necessidade de um maior refinamento da técnica.<sup>24-26</sup>

A análise ecocardiográfica do átrio esquerdo (AE) tem grande importância na pesquisa da gênese de certas patologias,<sup>6,11</sup> implicação prognóstica e aplicabilidade no tratamento intervencionista de certas arritmias cardíacas, como a ablação por radiofrequência da fibrilação atrial. A IA é uma ferramenta efetiva, com rapidez surpreendente na análise da função atrial esquerda, determinação dos seus volumes e dimensões, entretanto, ainda precisa de ajustes em decorrência da interposição do ar, costelas e formação de artefatos.<sup>2,16,21</sup>

## Avaliação da doença valvar


Uma área em rápida expansão da IA é a avaliação da segmentação valvar, importante na intervenção cardíaca estrutural minimamente invasiva.

A análise da morfologia tridimensional da valva mitral, usando ecocardiografia transesofágica tridimensional em tempo real, provou ser uma ferramenta valiosa para a avaliação de suas patologias. A morfologia pode ser analisada por meio de medições automatizadas dos parâmetros morfológicos, incluindo o comprimento e altura do anel, área das cúspides, ângulos e área e altura do prolapso. Um algoritmo de IA criado para avaliação morfológica do anel valvar e das cúspides (de valvas nativas ou reparadas cirurgicamente) mostrou boa reprodutibilidade intra e interobservador com coeficientes de variação abaixo de 12% e 15 %, respectivamente.<sup>27</sup>


As medidas do anel valvar aórtico e o diâmetro da via de saída do VE são cruciais para o implante percutâneo de endoprótese aórtica. Assim, a tecnologia de IA fornece informações precisas de suporte dinâmico para o planejamento pré-operatório, ajudando a aumentar a confiança do cirurgião.<sup>27,28</sup>

O desempenho relatado de quantificação rápida e semiautomática torna a IA promissora para futuras aplicações em ambientes clínicos, como na sala de cirurgia, onde a obtenção de resultados em curto espaço de tempo é capital. Aplicações da IA em Ecocardiografia são demonstradas nas Figuras de 1 a 4.







**Figura 1.** Demonstração e aferição ecocardiográfica por inteligência artificial (Ecocardiografia Transtorácica) de parâmetros do ventrículo esquerdo (Imagem à esquerda): Fração de Ejeção do ventrículo esquerdo (EF: 65%), do volume diastólico final (EDV, 159 mL) e volume sistólico final do ventrículo esquerdo (ESV, 56 mL), volume ejetado (SV, 104 mL), massa ventricular esquerda (125 g), do volume indexado do átrio esquerdo (53 ml/m<sup>2</sup>); Imagem à direita: Strain longitudinal global bidimensional do ventrículo esquerdo: valor médio: -10,2 % (VN > 18 %).



**Figura 2.** Demonstração e aferição ecocardiográfica por inteligência artificial (Ecocardiografia Transtorácica) de parâmetros do ventrículo direito (Imagem à esquerda); Imagem à direita: Fração de Ejeção do ventrículo direito (EF: 48,3%, VN > 40%), dos volumes diastólico final (EDV, 185,5 mL) e volume sistólico final do ventrículo direito (ESV, 95,9 mL), volume ejetado (SV, 89,6 mL).



**Figura 3.** Demonstração por Ecocardiografia Transesofágica Tridimensional (Imagem à esquerda, visão atrial esquerda) e por inteligência artificial derivada da imagem transesofágica das valvas cardíacas e da valva mitral, em paciente portador de doença de Barlow.



**Figura 4.** Demonstração e aferição ecocardiográfica por inteligência artificial (Ecocardiografia Transtorácica) de parâmetros do átrio esquerdo (Imagem à esquerda); Imagem à direita: Strain longitudinal do átrio esquerdo com a demonstração das fases da mecânica atrial (fase de reservatório, de condução e contração atrial). Paciente portador de fibrilação atrial apresentando dilatação atrial e grande diminuição dos componentes da mecânica atrial esquerda.

Hoje o uso na prática clínica ainda é limitado porque depende de abordagens complexas e da experiência do ecocardiografista.<sup>27</sup>

Nas Tabela 1 são demonstrados estudos em que a IA foi empregada para a análise ecocardiográfica em diferentes situações clínicas.

## Perspectivas da Inteligência artificial na Ecocardiografia

O futuro da IA na ecocardiografia está na combinação de dados clínicos e de imagem para melhor detectar a doença, prever resultados e adiantar riscos individuais.<sup>29</sup> Isso é útil particularmente na interação entre ecocardiografistas, cardiologistas clínicos, intervencionistas e cirurgiões. O objetivo da automação do processo de análise das imagens ecocardiográficas, como o reconhecimento automático das estruturas cardíacas, o cálculo de parâmetros funcionais clássicos e a determinação do *strain* global longitudinal do VE é a caracterização correta de certas patologias cardíacas.<sup>30</sup>

Com o estabelecimento da confiabilidade desta análise automática, o fluxo de trabalho nos laboratórios de ecocardiografia deverá mudar radicalmente. Enquanto o especialista atualmente gasta seu tempo extraindo parâmetros de imagens e os integra para chegar a um diagnóstico, o futuro laboratório extrairá automaticamente todos os dados relevantes e os alimentará diretamente em algoritmos de diagnóstico para apoiar a tomada de decisão.<sup>31,32</sup> O operador humano estará no controle do processo geral de diagnóstico, enquanto os computadores realizarão as medições, integrações e comparação de dados, quando solicitados.<sup>29</sup> Além disso, neste sistema, os critérios de diagnóstico e tomadas de decisão serão continuamente refinados e melhorados pela integração de bancos de dados cada vez maiores para que o perfil ecocardiográfico do paciente possa ser comparado a milhões de casos validados, fornecendo não apenas um diagnóstico, mas também uma estimativa de risco e os resultados em longo prazo relacionados às diferentes opções terapêuticas.<sup>32</sup> O aprendizado não supervisionado e de reforço

**Tabela 1.** Estudos empregando inteligência artificial para a análise ecocardiográfica em diferentes situações clínicas.

Autor (revista, ano)	Objetivo	Número de pacientes	Acurácia
Narang A, et al (JAMA Cardiol, 2021) <sup>18</sup>	Guiar operadores iniciantes à obter imagens ecocardiográficas	240	92,5-98,8%
Narang A, et al (European Heart Journal, 2018) <sup>22</sup>	Quantificação automática dos volumes das câmaras cardíacas esquerdas	20	90%
Volpato V, et al (Echocardiography, 2018) <sup>23</sup>	Analisar massa (VE)	23	87%
Wang S, et al (JACC Cardiovasc Imaging, 2021) <sup>25</sup>	Classificação da função ventricular (VE e VD) e massa (VE)	200	80-86%
Ahmad A, et al (Front Cardiovasc Med., 2021) <sup>26</sup>	Quantificação do VD comparada com RMN	170	Correlação (r) 0,79-0,94
Sotaquira M, et al (Ultrasound Med Biol, 2015) <sup>27</sup>	Segmentação e qualificação das cúspides e anel mitral de forma semi automática	33	-
Asch F, et al (AHA, 2021) <sup>*29</sup>	Avaliação da Fração de Ejeção (VE)	167 / 66	86-95% / 84% (correlação intraclass)
Samad M, et al (JACC, 2019) <sup>34</sup>	Previsão da sobrevida, diagnóstico diferencial entre hipertrofia em atletas e CMH	171.510 159(CMH)	96%
Dabiri Y, et al (Front Cardiovasc Med., 2021) <sup>35</sup>	Atlas de predição para intervenções com emprego de MitralClip	29	-
Madani A, et al (NPJ Digital Medicine, 2018) <sup>36</sup>	Classificação ecocardiografica com Aprendizado Profundo	200.000(imagens)	97,8%
Ghorbani A, et al (NPJ Digital Medicine, 2020) <sup>37</sup>	Interpretação ecocardiografica com Aprendizado Profundo	2850	95%

VE: Ventrículo Esquerdo. VD: Ventrículo Direito; CMH: Cardiomiopatia hipertrófica; RMN: Ressonância magnética nuclear. \*Pesquisa realizou dois protocolos com distintos participantes e resultados.

são promessas para o desenvolvimento de algoritmos de previsão de risco automatizados que podem ser usados para orientar o atendimento clínico. Em tempo, técnicas de aprendizagem não supervisionadas deverão ser usadas para fenotipagem mais precisa de doenças complexas, e algoritmos de aprendizagem de reforço poderão aumentar de forma inteligente os prestadores de cuidados de saúde.<sup>33-38</sup>

### Limitações da Inteligência artificial

Há desafios e limitações que precisam ser considerados sobre a IA. Mesmo na configuração de um algoritmo teoricamente perfeito, se os dados de sua base são de má qualidade ou enviesados, a sua interpretação também o será.<sup>24</sup> Padrões uniformes oferecidos pelos fabricantes devem ser enfatizados, permitindo assim a integração entre os diferentes algoritmos a fim que eles funcionem em equipamentos diferentes de forma homogênea. Seria útil ter um conjunto de padrões para gerenciamento de dados de IA, semelhante aos sistemas de comunicação e arquivamento de imagens e aos formatos de imagem digital em medicina.

Esses padrões para gerenciamento incluem nomenclatura padronizada usada e possibilitam criar um sistema uniforme de armazenamento e recuperação de dados.

### CONCLUSÃO

O emprego da inteligência artificial em Ecocardiografia representa avanço incontestável em relação à análise de grande volume de informações (*big data*) resultando em maior acurácia, reprodutibilidade e otimização do tempo para a realização dos exames em ambientes hospitalar Sua eventual adoção nas práticas clínicas pode representar grande aplicação para a análise de grandes populações e fornecer importantes parâmetros de intervenção médica.

### CONFLITOS DE INTERESSE

Os autores declaram não possuir conflitos de interesse na realização deste trabalho.

### REFERÊNCIAS

- Alsharqi M, Woodward WJ, Murnith JA, Markham DC, Upton R, Leeson P. Artificial intelligence and echocardiography. *Echo Res Pract.* 2018;5(4):R115-R125.
- Kusunose K, Haga A, Abe T, Sata M. Utilization of artificial intelligence in echocardiography. *Circ J.* 2019;83(8):1623-29.
- Vieira ML, Nomura CH, Tranchesi B, Oliveira WA, Naccarato G, Serpa BS, et al. Real-time three-dimensional echocardiographic left ventricular systolic assessment: side-by-side comparison with 64-slice multi-detector cardiac computed tomography. *Eur J Echocardiogr.* 2010;11(3):257-63.
- Oliveira W, Campos O, Cintra F, Matos L, Vieira ML, Rollim B, et al. Impact of continuous positive airway pressure treatment on left atrial volume and function in patients with obstructive sleep apnoea assessed by real-time three-dimensional echocardiography. *Heart.* 2009; 95(22):1872-8.
- Vieira MLC, Cury AF, Naccarato G, Oliveira WA, Mônico CG, Rodrigues AC, et al. Analysis of left ventricular regional dyssynchrony: comparison between real time 3D echocardiography and tissue Doppler imaging. *Echocardiography.* 2009;26(6):675-83.
- Lang RM, Badano LP, Mor-Avi V, Afzalpoor J, Armstrong A, Ernande

- L, et al. Recommendations for cardiac chamber quantification by echocardiography in adults: an update from the American Society of Echocardiography and the European Association of Cardiovascular Imaging. *J Am Soc Echocardiogr.* 2015;28(1):1-39.e14.
7. Gimenes VM, Vieira ML, Andrade MM, Pinheiro Jr J, Hotta VT, Mathias Jr W. Standard values for real-time transthoracic three-dimensional echocardiographic dyssynchrony indexes in a normal population. *J Am Soc Echocardiogr.* 2008; 21(11):1229–35.
  8. Vieira ML, Cury AF, Gustavo N, Oliveira WA, Monaco CG, Cordovil A, et al. Ventricular dyssynchrony index: comparison with 2D and three-dimensional ejection fraction. *Arq Bras Cardiol.* 2008;91(3): 142–7:56–62.
  9. Gutierrez-Chico JL, Zamorano JL, Prieto-Moriche E, Hernandez-Antolin RA, Bravo-Amaro M, Perez de Isla L, et al. Real-time three-dimensional echocardiography in aortic stenosis: a novel, simple, and reliable method to improve accuracy in area calculation. *Eur Heart J.* 2008; 29(10):1296–306.
  10. Lancellotti P, Pibarot P, Chambers J, Edvardsen T, Delgado V, Dulgheru R, et al. Recommendations for the imaging assessment of prosthetic heart valves: a report from the European Association of Cardiovascular Imaging endorsed by the Chinese Society of Echocardiography, the Inter-American Society of Echocardiography, and the Brazilian Department of Cardiovascular Imaging. *Eur Heart J Cardiovasc Imaging.* 2016; 17(6):589–90.
  11. Vieira ML, Silva MC, Wagner CR, Kajita LJ, Oliveira WA, Samesina N, et al. Left atrium reverse remodeling in patients with mitral valve stenosis after percutaneous valvuloplasty: a 2- and 3-dimensional echocardiographic study. *Rev Esp Cardiol.* 2013;66(1):17–23.
  12. Endo Y, Maddukuri PV, Vieira ML, Pandian NG, Patel AR. Quantification of right ventricular volumes and function by real time three-dimensional echocardiographic longitudinal axial plane method: validation in the clinical setting. *Echocardiography.* 2006;23(10):853–9.
  13. Addetia K, Muraru D, Veronesi F, Jenei C, Cavalli G, Besser SA, et al. 3-Dimensional echocardiographic analysis of the tricuspid annulus provides new insights into tricuspid valve geometry and dynamics. *JACC Cardiovasc Imaging.* 2019;12(3):401–12.
  14. Vieira MLC, Branco CEB, Gazola ASL, Vieira PPAC, Benvenuti LA, Demarchi LMMF, et al. 3D Echocardiography for Rheumatic Heart Disease Analysis: Ready for Prime Time. *Front Cardiovasc Med.* 2021;8:676938.
  15. Kuehn BM. Cardiac imaging on the cusp of an artificial intelligence revolution. *Circulation.* 2020;141(15):1266-7.
  16. Chu WK, Raeside DE. Fourier analysis of the echocardiogram. *Phys Med Biol.* 1978;23(1):100-5.
  17. Zhou J, Du M, Chang S, Chen Z. Artificial intelligence in echocardiography: detection, functional evaluation, and disease diagnosis. *Cardiovasc Ultrasound.* 2021;19(1):29.
  18. Narang A, Bae R, Thomas Y, Surette S, Cadieu C, Chaudry A, Martin Rp, et al. Utility of a Deep-Learning Algorithm to Guide Novices to Acquire Echocardiograms for Limited Diagnostic Use. *JAMA Cardiol.* 2021;6(6):624-32.
  19. Seetharam K, Raina S, Sengupta PP. The Role of Artificial Intelligence in Echocardiography. *Curr Cardiol Rep.* 2020;22(9):99.
  20. Genovese D, Rashedi N, Narang A, Addetia K, Patel AR, Prater D, et al. Machine Learning-Based Three-Dimensional Echocardiographic Quantification of Right Ventricular Size and Function: Validation Against Cardiac Magnetic Resonance. *J Am Soc Echocardiogr.* 2019;32(8):969-77.
  21. Davis A, Billick K, Horton K, Jankowski M, Knoll P, Marshall JE, et al. Artificial Intelligence and Echocardiography: A Primer for Cardiac Sonographers. *J Am Soc Echocardiogr.* 2020;33(9):1061-6.
  22. Narang A, Mor-Avi V, Prado A, Volpato V, Prater D, Tamborini G, et al. Machine learning based automated dynamic quantification of left heart chamber volumes. *Eur Heart J Cardiovasc Imaging.* 2019;20(5):541-9.
  23. Volpato V, Mor-Avi V, Narang A, Prater D, Gonçalves A, Tamborini G, et al. Automated, machine learning-based, 3D echocardiographic quantification of left ventricular mass. *Echocardiography.* 2019;36(2):312–9.
  24. Gandhi S, Mosleh W, Shen J, Chow CM. Automation, machine learning, and artificial intelligence in echocardiography: A brave new world. *Echocardiography.* 2018;35(9):1402-18.
  25. Wang S, Patel H, Miller T, Ameyaw K, Narang A, Chauhan D, et al. AI Based CMR Assessment of Biventricular Function. *JACC Cardiovasc Imaging.* 2021;S1936-878X(21)00638-0.
  26. Ahmad A, Li He, Wan X, Zhong Y, Zhabg Y, Liu J, et al. Feasibility and Accuracy of a Fully Automated Right Ventricular Quantification Software With Three-Dimensional Echocardiography: Comparison With Cardiac Magnetic Resonance. *Front Cardiovasc Med.* 2021;8:732893.
  27. Sotaquira M, Pepi M, Fusini L, Maffessanti F, Lang RM, Caiani EG. Semi-automated segmentation and quantification of mitral annulus and leaflets from transeophageal 3-D echocardiographic images. *Ultrasound Med Biol.* 2015;41(1):251-67.
  28. Yoon YE, Kim S, Chang HJ. Artificial intelligence and echocardiography. *J Cardiovasc Imaging.* 2021;29(3):193-204.
  29. Asch FM, Mor-Avi V, Rubenson D, Goldstein S, Saric M, Mikati I, et al. Deep Learning-Based Automated Echocardiographic Quantification of Left Ventricular Ejection Fraction: A Point-of-Care Solution. *Circ Cardiovasc Imaging.* 2021;14(6):e012293.
  30. Tsang W, Salgo IS, Medvedofsky D, Takeuchi M, Prater D, Weinert L, et al. Transthoracic 3D Echocardiographic Left Heart Chamber Quantification Using an Automated Adaptive Analytics Algorithm. *JACC Cardiovasc Imaging.* 2016 ;9(7):769-82.
  31. D'hooge J, Fraser AG. Learning about machine learning to create a self-driving Echocardiographic laboratory: Technical considerations. *Circulation.* 2018;138(16):1636–8.
  32. Kusunose K. Steps to use artificial intelligence in echocardiography. *J Echocardiogr.* 2021;19(1):21-7.
  33. Shameer K, Johnson KW, Glicksberg BS, Dudley JT, Sengupta PP. Machine learning in cardiovascular medicine: Are we there yet? *Heart.* 2018 ;104(14):1156-64.
  34. Samad MD, Ulloa A, Wehner GJ, Jing L, Hartzel D, Good CW, Williams BA, et al. Predicting Survival From Large Echocardiography and Electronic Health Record Datasets: Optimization With Machine Learning. *JACC Cardiovasc Imaging.* 2019;12(4):681-9.
  35. Dabiri Y, Yao J, Mahadevan VS, Gruber D, Arnaout R, Gentsch W, et al. Mitral Valve Atlas for Artificial Intelligence Predictions of MitraClip Intervention Outcomes. *Front Cardiovasc Med.* 2021;8:759675.
  36. Madani A, Arnaout R, Mofrad M, Arnaout R. Fast and accurate view classification of echocardiograms using deep learning. *NPJ Digit Med.* 2018;1:6.
  37. Ghorbani A, Ouyang D, Abid A, He B, Chen JH, Harrington RA, et al. Deep learning interpretation of echocardiograms. *NPJ Digit Med.* 2020;3(1):1–10.
  38. Paixão GMM, Santos BC, Araújo RA, Ribeiro MH, Moraes JI, Ribeiro AL. Machine Learning na Medicina: Revisão e Aplicabilidade. *Arq Bras Cardiol.* 2022; 118(1): 95-102.

# APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL EM IMAGEM CARDIOVASCULAR: EM MÉTODOS GRÁFICOS E ELETROCARDIOGRAFIA

## APPLICATION OF ARTIFICIAL INTELLIGENCE IN CARDIOVASCULAR IMAGING: GRAPHICAL METHODS AND ELECTROCARDIOGRAPHY



Clique para acessar  
o Podcast

Camila Rocon de Lima  
Andretta<sup>1</sup>

1. Hospital do Coração de São Paulo.  
São Paulo, SP, Brasil.

Correspondência:  
Camila Rocon de Lima Andretta.  
camilarocon@yahoo.com.br

### RESUMO

A transformação digital é uma realidade na área da saúde em todo o mundo, e a inteligência artificial (IA) permite o desenvolvimento de métodos diagnósticos de maior precisão dentro da cardiologia, sinalizando alterações subclínicas e permitindo diagnósticos mais precoces. Por meio da análise de grandes bancos de dados de eletrocardiograma (ECG) por ferramentas como aprendizado de máquina (ML, *machine learning*), redes neurais são desenhadas, permitindo o desenvolvimento de algoritmos capazes de fornecer inúmeras informações sobre o quadro dos pacientes e prever a possibilidade de desenvolvimento de doenças graves, o que torna o ECG, um método tão antigo, acessível e de baixo custo, um biomarcador poderoso e não invasivo. Os algoritmos desenvolvidos a partir do traçado de ECG para detecção de risco aumentado de infarto agudo do miocárdio e morte súbita, disfunção sistólica do ventrículo esquerdo, valvopatias, identificação de distúrbios eletrolíticos, sinalização dos pacientes com risco de desenvolvimento de fibrilação atrial e eventos embólicos decorrentes dessa arritmia, são algumas das utilizações promissoras dessa técnica e permitem a abordagem precoce de afecções e a redução da morbidade e da mortalidade em geral. A IA auxilia o profissional de saúde acelerando os processos, reduzindo erros e o apoiando no diagnóstico e tomada de decisões. Mas a figura e experiência do profissional ainda é insubstituível para validar esses resultados.

**Descritores:** Inteligência Artificial, Eletrocardiograma; Telemedicina, métodos gráficos.

### ABSTRACT

*Digital transformation is a reality in healthcare worldwide, and artificial intelligence (AI) enables the development of more accurate diagnostic methods within cardiology, signaling subclinical changes and allowing earlier diagnoses. Through the analysis of large electrocardiogram (ECG) databases by tools such as machine learning (ML), neural networks are designed, allowing the development of algorithms that provide extensive information on the condition of patients and predict the possibility of developing serious diseases, turning the ECG, such a long-standing, accessible, and low-cost method, into a powerful and non-invasive biomarker. Algorithms developed from ECG tracing to detect increased risk of acute myocardial infarction and sudden death, left ventricular systolic dysfunction, and valvular heart disease; to identify electrolytic disturbances; and to signal patients at risk of developing atrial fibrillation and embolic events resulting from this arrhythmia are some of the promising uses of this technique, allowing early management of conditions and reducing overall morbidity and mortality. AI helps healthcare professionals by accelerating processes, reducing errors, and supporting them in diagnosis and decision making. But the role of the experienced professional in validating these results is still essential.*

**Keywords:** Artificial Intelligence; Electrocardiography; Telemedicine.

### INTRODUÇÃO

As doenças cardiovasculares (DCV) constituem a maior causa de morbidade e mortalidade no Brasil e no mundo. Grande parte dos desfechos cardiovasculares poderiam ser evitados ou diagnosticados de forma precoce, com

exames cardiológicos de rotina, que cada vez mais nos dão informações relevantes não apenas sobre o estado atual do paciente, mas também sobre riscos de evoluções e desfechos desfavoráveis.

O desenvolvimento da Inteligência Artificial (IA) teve início

em 1950 e, desde então, as diferentes possibilidades de utilizar tecnologias que permitam uma atuação mais eficaz na prevenção, diagnóstico, tratamento e acompanhamento das doenças em geral, abre perspectivas muito relevantes, com o intuito de prestar melhores cuidados personalizados à população e comunidades e faz com que as previsões dos filmes de ficção científica do passado se tornem uma realidade.<sup>1-3</sup> A transformação digital na área da saúde aumentou o interesse por métodos diagnósticos em cardiologia com maior precisão e a IA, através do *Machine Learning* (ML) e *Deep Learning* (DL), vem para identificar padrões de interação entre diferentes variáveis, visando formar subgrupos de padrões que possam ser aplicados na população geral, criando algoritmos que possam detectar precocemente o risco do desenvolvimento de afecções, como insuficiência cardíaca, padrões relacionados com risco de morte súbita, arritmias cardíacas, hipertensão arterial, hipertensão pulmonar, hipercalemia, anemia, lesões valvares, entre outras.<sup>4-9</sup>

A utilização do DL permite a descoberta de dados e padrões que não seriam possíveis em uma perspectiva humana. O eletrocardiograma (ECG), Holter 24 h e outros métodos gráficos são exemplos da aplicação da IA na identificação, previsão e priorização de diagnósticos mais graves, de rastreamento de doenças, assim como também a otimização de recursos.<sup>4</sup> Recentemente, por exemplo, estudo da *Mayo Clinic* propôs através de algoritmo desenvolvido por DL, o diagnóstico de infecção pelo coronavírus (Covid19), assim como sinalizou indivíduos que teriam maior risco de evoluir com acometimento cardíaco pelo vírus, através de alterações eletrocardiográficas detectadas apenas pelo modelo proposto pela IA.<sup>5,6</sup>

Vivemos um momento de grandes mudanças na interpretação dos métodos diagnósticos e a aplicação da IA na interpretação do ECG e outros métodos gráficos é um exemplo do efeito transformador da IA no diagnóstico e condução das doenças cardiovasculares, permitindo o desenho de padrões de ECG específicos de cada doença, que seriam irreconhecíveis pelo olho humano.<sup>1</sup>

## APLICAÇÃO DA IA NO PRÁTICA CLÍNICA

Através da análise de grandes bancos de dados de ECG com informações confiáveis, associados a dados clínicos, a IA utilizando, consegue identificar padrões, permitindo o desenvolvimento de algoritmos capazes de prever idade, sexo, raça, correlação com cardiopatias e prognósticos dos pacientes de forma precoce. A utilização do ECG, um método tão antigo, acessível e de baixo custo para prever alterações cardíacas e não cardíacas de forma precoce, realmente se torna um divisor de águas dentro do rastreamento de doenças cardiológicas, tornado esse método um biomarcador poderoso e não invasivo.

Padrões eletrocardiográficos como arritmias, disfunção ventricular sistólica, cardiomiopatia hipertrófica, doenças genéticas e outras afecções, podem ser sugeridos como um método de rastreamento para a população em geral, identificando alterações que poderiam não ser vistas mesmo aos olhos de especialistas.

A análise de dados extraídos do Holter 24h permite inferir e diagnosticar pacientes que teriam maior possibilidade de evolução para insuficiência cardíaca ou desenvolvimento de

diferentes arritmias. O DL aplicado a esse método tem se mostrado promissor e uma gama de estudos estão sendo publicados.<sup>10</sup> Santala et al., avaliaram um sistema de monitoramento em formato de cinto acoplado a um smartphone, em que a avaliação de uma única derivação, através de algoritmos de IA, foi capaz de detectar a fibrilação atrial (FA) com 97,5% de precisão, 100% de sensibilidade e 95,4% de especificidade, sendo referido como uma boa experiência pelo usuário, em relação ao Holter 24h.<sup>11</sup>

Algumas aplicações da IA na detecção de doenças cardiovasculares e não cardiovasculares são discutidas abaixo neste texto:

## Tele-eletrocardiografia

Com a disponibilização de eletrocardiógrafos digitais, o serviço de tele-eletrocardiografia (Tele-ECG) permite levar laudos qualificados para regiões distantes, onde há vazios assistenciais e escassez de profissionais especialistas ou com expertise em laudos mais complexos. Alguns serviços geram uma infinidade de dados através destes relatórios e, através da IA essas infinidades de informações podem ser avaliadas e correlacionadas com dados clínicos, sendo possível o desenvolvimento de algoritmos que permitem identificar laudos classificados como normais ou alterados. A identificação de exames alterados pela IA (arritmias, elevação do segmento ST com suspeita de infarto agudo do miocárdio, bloqueios átrio-ventriculares avançados, identificação de risco de parada cardiorespiratória) pode categorizá-los para que sejam laudados com prioridade, reduzindo o tempo de diagnóstico e de conduta para o paciente.<sup>9</sup>

Outra utilização da IA no Tele-ECG é a documentação de diferentes traçados de um mesmo indivíduo ao longo do tempo, podendo-se assim correlacionar, através de DL, quais alterações podem inferir a possibilidade de determinado paciente evoluir com arritmias, como a fibrilação atrial (FA), ou até mesmo de valorizar pequenas alterações no segmento ST que estão relacionadas a eventos isquêmicos futuros.<sup>12-15</sup>

## Detecção de disfunção sistólica do ventrículo esquerdo

A insuficiência cardíaca (IC) é uma entidade responsável por grande parcela de morbidade e mortalidade dentro das afecções cardiológicas. Sua abordagem precoce pode evitar a progressão para formas mais graves e até permitir a introdução de tratamentos que podem reverter totalmente e doença, em casos específicos. O diagnóstico de IC em setores de urgência e emergência, nos casos em que o paciente dá entrada com dispnéia, é sempre um desafio, uma vez que as causas desta sintomatologia englobam uma grande gama de entidades nosológicas. Identificação precoce e precisa destes pacientes permite a introdução precoce das terapias específicas, podendo reduzir o tempo e custos de internação, assim como readmissões hospitalares.

Estudo da Mayo Clinic,<sup>15,16</sup> avaliando cerca de 45 mil pacientes, resultou em um modelo capaz de identificar, a partir do traçado de ECG de 12 derivações, pacientes com disfunção sistólica do ventrículo esquerdo, com fração de ejeção do ventrículo esquerdo (FEVE) inferior a 35% ao ecocardiograma, com uma AUC de 0.93 e de 0.85 para aqueles

pacientes com FEVE inferior a 50%. E naqueles casos em que o modelo detectou disfunção sistólica erroneamente, observou-se uma propensão quatro vezes maior a desenvolverem disfunção em um seguimento de 3,4 anos, quando comparados aos pacientes não sinalizados pelo modelo. Tal achado sugere a capacidade do modelo de DL detectar e/ou prever acometimento sistólico do ventrículo esquerdo (VE) mais precocemente em relação à queda da FEVE no ecocardiograma. Outro dado relevante é a precisão deste algoritmo em detectar baixos valores de FEVE, mesmo quando usado ECG de apenas uma derivação, como nos casos registrados por smartphones ou estetoscópios.

Ter a disponibilidade de um algoritmo que permita indicar ou inferir um paciente com insuficiência cardíaca pelo ECG abre várias possibilidades para disponibilização desta ferramenta como o seguimento clínico de pacientes com diagnóstico de IC sistólica que estão recebendo terapia medicamentosa, sinalização de pacientes com dispnéia em setores de urgência que não contam com serviços de ecocardiografia de urgência, seguimento de pacientes em uso de drogas cardiotóxicas (como pacientes oncológicos), guiando a necessidade de tratamento ou intervenção de pacientes com valvopatias, detecção de pacientes com quadros graves que podem evoluir com acometimento da fração de ejeção do VE como sepsis, entre inúmeras possibilidades.<sup>17</sup>

Em maio de 2020, o *Food and Drug Administration* (FDA) emitiu uma autorização de uso emergencial deste algoritmo por profissionais de saúde, para detecção de disfunção sistólica do ventrículo esquerdo, com FEVE inferior a 40%, em pacientes acometidos pela infecção pela Covid 19, o que pode sinalizar a necessidade de abordagem medicamentosa precoce e mudar o prognóstico destes indivíduos.<sup>6,18</sup>

### Identificação da idade biológica

A partir da análise de mais de 1,5 milhões de traçados de ECG, utilizando métodos de IA, pesquisadores do projeto *Clinical Outcomes in Digital Electrocardiography* (CODE), da Universidade de Minas Gerais, desenvolveram um modelo capaz de prever a idade cronológica do paciente. Observaram que, quando o sistema subestimava ou superestimava a "idade eletrocardiográfica" do paciente, na verdade ele estava inferindo sua idade biológica, e os pacientes com idade predita maior que a biológica, tinham maior risco de mortalidade, o que tornou esse algoritmo uma ferramenta promissora para predição de riscos e mortalidade geral dos pacientes.<sup>7-8</sup>

### Identificação de estenose aórtica

As doenças valvares também são responsáveis por acometimento cardíaco que leva à aumento da morbidade. A estenose aórtica (EAo) também é um exemplo disso e a troca valvar precoce tem demonstrado benefícios nos pacientes com poucos sintomas e estenose aórtica grave. Cohen-Shelly et al., após avaliar quase 250 mil pacientes com ecocardiograma e ECG de 12 derivações, através da utilização de redes neurais, desenvolveram um modelo de DL para capaz de identificar pacientes com EAo moderada a grave, com desempenho muito bom com a área abaixo da curva (AUC) de 0.85, comparável a outros exames de rastreamento, como Papanicolau para detectar câncer de colo

de útero (AUC 0.71). Os autores mostraram que a análise de alterações eletrocardiográficas, desde as muito sutis até as mais complexas, utilizando a IA, é capaz ainda de prever o desenvolvimento de EAo, comparando grupos falso-positivos e verdadeiros-negativos na análise de subgrupos. (Figura 1) Modelos como este podem ser usados para rastreamento populacional de EAo, visando diagnóstico mais precoce, antes da evolução para arritmias, insuficiência cardíaca e morte súbita, que são evoluções da doença.<sup>19</sup> Estudos promissores têm sido realizados para correlacionar as alterações eletrocardiográficas com outras valvopatias.<sup>6</sup>

### Identificação de distúrbios eletrolíticos

A utilização do ECG vai além do diagnóstico de doenças cardiovasculares, entrando também no diagnóstico de distúrbios eletrolíticos e anemia, que são importantes marcadores para manter a função celular e a homeostase. Em 2019 Galloway et al., propuseram um modelo de IA usando DL para rastrear a hipercalemia, mesmo em níveis mais baixos, em pacientes portadores de doença renal crônica (DRC). Utilizando as derivações DI e DII ECG, o algoritmo detectou níveis séricos de potássio elevado com uma AUC de 0,853 a 0,883 e uma sensibilidade de 88,9% a 91,3%.<sup>5</sup> Kwon JM et al., em estudo multicêntrico avaliando mais de 90 mil pacientes desenvolveu modelo que demonstrou importante desempenho na detecção de diferentes distúrbios eletrolíticos na avaliação das ondas P, complexo QRS e onda T, propondo o ECG como método não invasivo para diagnóstico.<sup>20,21</sup>

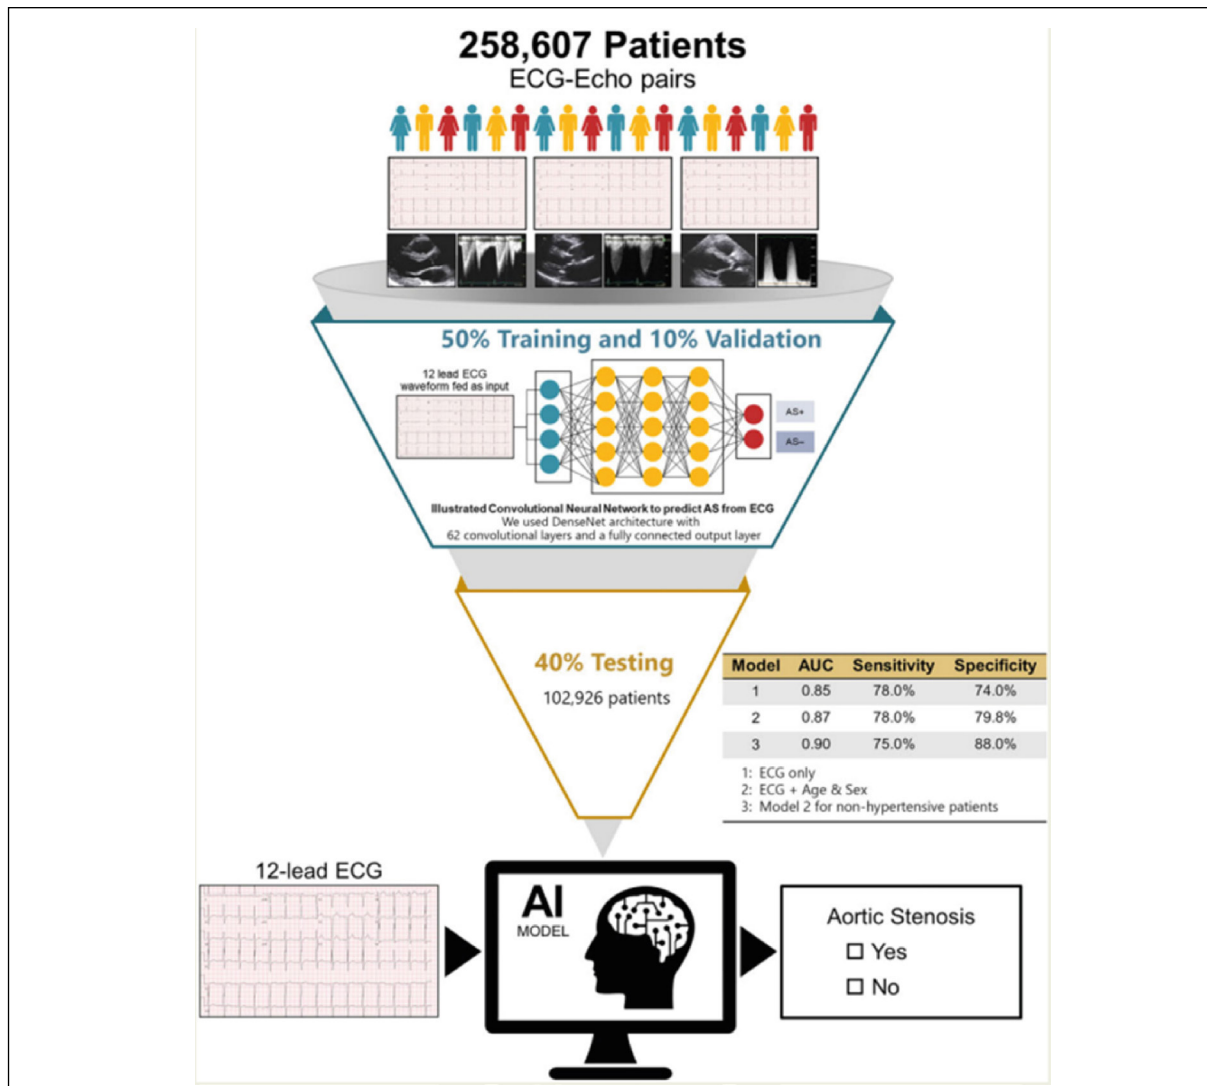
A aplicação de algoritmos como estes permite ao médico atender pacientes com dificuldade de acessar sistemas de saúde, de forma remota, reavaliando manutenção ou ajuste de medicações, assim como a evolução da doença renal e necessidade de hemodiálise.<sup>22</sup>

### Identificação de fibrilação atrial paroxística

A fibrilação atrial paroxística é responsável por relevante número de casos de acidente vascular cerebral (AVC) de causa embólica, com prejuízo à qualidade de vida da população e aumento da morbi-mortalidade. Seu diagnóstico precoce permite a introdução de anticoagulação, nos casos indicados, e início de terapia que pode reverter a arritmia, manter o paciente em ritmo sinusal e prevenir a morbimortalidade relacionada à FA. O uso de smartphones representa uma nova realidade onde, a partir deste dispositivo, a interpretação de apenas uma derivação, o diagnóstico da FA e acionamento do médico ou serviço de saúde, pode ser realizada, baseando-se em dados de algoritmo de DL.<sup>23</sup>

Estudos demonstram a possibilidade de identificar, a partir de um ECG de 12 derivações em ritmo sinusal, o risco do indivíduo ser portador de FA paroxística.<sup>24</sup> Assim como nos demais algoritmos de outras doenças, seu desenvolvimento está relacionado a dados clínicos conhecidos, permitindo traçar o "perfil" do paciente que tem maior chance de desenvolver esta entidade, baseando-se em algumas características como presença de ectopia atrial, variabilidade da frequência cardíaca, hipertrofia do VE, além de outros fatores ainda não óbvios aos olhos humanos. A correlação do desenvolvimento desta arritmia, baseada em achados do Holter 24 h também tem sido realizada.<sup>25,26</sup>

Algoritmos baseados em DL estão sendo propostos para



**Figura 1.** Eletrocardiograma avaliado pela Inteligência Artificial para triagem de estenose aórtica usando redes neurais. Cohen-Shelly M, Attia ZI, Friedman PA, Ito S, Essayagh BA, Ko WY, et al. Electrocardiogram screening for aortic valve stenosis using artificial intelligence. *Eur Heart J.* 2021;42(30):2885-96.<sup>19</sup>

estratificar o risco do paciente com FA paroxística evoluir para AVC isquêmico em curto prazo, oferecendo valor prognóstico incremental para estratificação de risco inferida pelo escore de CHA2DS2-VASc. Esses modelos ainda precisam de estudos para serem validados, mas representa uma evolução muito grande no tratamento e condução dos pacientes com FA paroxística, podendo alertar o médico a uma introdução oportuna mais precoce de anticoagulação, no intuito de evitar a evolução para eventos embólicos.<sup>27-32</sup>

## Diagnóstico de hipertensão arterial

A hipertensão arterial está relacionada ao acometimento de muitos órgãos e sistemas como o cardiovascular, renal, oftalmológico, entre outros. Seu diagnóstico e tratamento precoces podem diminuir muito a morbimortalidade dos pacientes e a IA também promove possibilidades neste contexto. Estudo avaliando pacientes que foram submetidos a monitorização ambulatorial da pressão arterial (MAPA) e tiveram seus dados correlacionados com o ECG mostraram

que o traçado pode detectar hipertensão arterial com uma precisão de 99,9%, permitindo seu uso em ambientes hospitalares e em locais onde a utilização do MAPA é limitada. Outros dispositivos e aplicativos de smartphones vêm sendo estudados para monitorização não invasiva, com dados promissores para o diagnóstico da HAS.<sup>33</sup>

Apesar de todas essas facetas e aplicações da IA nas afecções cardíacas, é importante ressaltar que até o presente momento, os algoritmos foram idealizados e testados por mãos humanas. A IA auxilia o profissional de saúde acelerando os processos, reduzindo erros e o apoiando no diagnóstico e tomada de decisões. Mas a figura e experiência do profissional ainda é insubstituível para validar esses resultados.

## CONCLUSÃO

A transformação digital é uma realidade na área da saúde mundialmente, e a IA é um verdadeiro trunfo para o desenvolvimento da área médica e, sua expansão para a área assistencial, já está levando a avanços promissores, com

enorme potencial disruptivo. O desenvolvimento da IA nos métodos gráficos ocorreu e ocorre com algumas limitações e desafios e requerem qualidade dos dados analisados, avaliação em diferentes populações, segurança dos dados dos pacientes, validação externa com outros bancos de dados e certificação de resultados condizentes ou mais expressivos do que as técnicas atuais de diagnóstico.

Muitas das aplicações da IA citadas ainda estão em análise e necessitam de mais estudos para que sejam aplicadas na vida prática. Fato é que sua utilização já permite sugerir casos potencialmente mais graves, aumentar a precisão diagnóstica e sinalizar diagnósticos de forma mais precoce, o que é de enorme importância no campo da cardiologia onde temos uma grande gama de doenças que são preveníveis, além daquelas que têm evoluções irreversíveis, quando não tratadas precocemente.

Além de toda a relevância na cardiologia preventiva, a utilização da IA está demonstrando-se uma ferramenta com grande potencial de identificação fenotípica de doenças e os profissionais médicos precisam estar alertas e serem treinados para a utilização desta ferramenta que, com certeza irá transformar a prática clínica. Vale a pena ressaltar, porém, a importância dos preceitos éticos que devem ser um pilar norteador da implantação desta tecnologia no cotidiano das instituições e dos profissionais de saúde.

## CONFLITOS DE INTERESSE

Os autores declaram não possuir conflitos de interesse na realização deste trabalho.

## REFERÊNCIAS

- Souza Filho EM, Fernandes FA, Soares CLA, Seixas FL, Santos AASMD, Gismondi RA, et al. Artificial Intelligence in Cardiology: Concepts, Tools and Challenges - "The Horse is the One Who Runs, You Must Be the Jockey". *Arq Bras Cardiol.* 2020;114(4):718-25. <https://pubmed.ncbi.nlm.nih.gov/32491009/>
- Rocon C, Tabassian M, Tavares de Melo MD, Araujo Filho JA, Grupi CJ, Parga Filho JR, et al. Biventricular imaging markers to predict outcomes in non-compaction cardiomyopathy: a machine learning study. *ESC Heart Fail.* 2020;7(5):2431-39. doi: 10.1002/ehf2.12795. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7524220/>
- Tavares de Melo MD, Araujo-Filho JAB, Barbosa JR, Rocon C, Miranda Regis CD, Santos Felix A, et al. A machine learning framework for the evaluation of myocardial rotation in patients with non-compaction cardiomyopathy. *PLoS One.* 2021;16(11):e0260195. <https://pubmed.ncbi.nlm.nih.gov/34843536/>
- Siontis KC, Noseworthy PA, Attia ZI, Friedman PA. Artificial intelligence-enhanced electrocardiography in cardiovascular disease management. *Nat Rev Cardiol.* 2021;18(7):465-78. doi: 10.1038/s41569-020-00503-2. <https://pubmed.ncbi.nlm.nih.gov/33526938/>
- Lyon A, Mincholé A, Martínez JP, Laguna P, Rodriguez B. Computational techniques for ECG analysis and interpretation in light of their contribution to medical advances. *J R Soc Interface.* 2018;15(138):20170821. doi: 10.1098/rsif.2017.0821. <https://pubmed.ncbi.nlm.nih.gov/29321268/>
- Attia ZI, Kapa S, Dugan J, Pereira N, Noseworthy PA, Jimenez FL, et al. Discover Consortium (Digital and Noninvasive Screening for COVID-19 with AI ECG Repository). Rapid Exclusion of COVID Infection With the Artificial Intelligence Electrocardiogram. *Mayo Clin Proc.* 2021;96(8):2081-94. doi: 10.1016/j.mayocp.2021.05.027. <https://pubmed.ncbi.nlm.nih.gov/34353468/>
- Li Q, Rajagopalan C, Clifford GD. A machine learning approach to multi-level ECG signal quality classification. *Comput Methods Programs Biomed.* 2014;117(3):435-47. doi: 10.1016/j.cmpb.2014.09.002. <https://pubmed.ncbi.nlm.nih.gov/25306242/>
- Ribeiro AH, Ribeiro MH, Paixão GMM, Oliveira DM, Gomes PR, Canazart JA, et al. Automatic diagnosis of the 12-lead ECG using a deep neural network. *Nat Commun.* 2020;11(1):1760. doi: 10.1038/s41467-020-15432-4. Erratum in: *Nat Commun.* 2020;11(1):2227. <https://pubmed.ncbi.nlm.nih.gov/32273514/>
- Kwon J-M, Kim K-H, Medina-Inojosa J, Jeon KH, Park J, Oh BH. Artificial intelligence for early prediction of pulmonary hypertension using electrocardiography. *J Heart Lung Transplant.* 2020;39(8):805-14. <https://pubmed.ncbi.nlm.nih.gov/32381339/>
- Cho Y, Kwon J-M, Kim K-H, Medina-Inojosa JR, Jeon KH, Cho S, et al. Artificial intelligence algorithm for detecting myocardial infarction using six-lead electrocardiography. *Sci Rep.* 2020;10(1):20495. doi: 10.1038/s41598-020-77599-6. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7686480/>
- Soh DCK, Ng EYK, Jahmunah V, Oh SL, Tan RS, Acharya UR. Automated diagnostic tool for hypertension using convolutional neural network. *Comput Biol Med.* 2020;126:103999. <https://pubmed.ncbi.nlm.nih.gov/32992139/> doi: 10.1016/j.combiomed.2020.103999.
- Kwon JM, Kim KH, Jeon KH, Lee SY, Park J, Oh BH. Artificial intelligence algorithm for predicting cardiac arrest using electrocardiography. *Scand J Trauma Resusc Emerg Med.* 2020;28(1):98. <https://sitrmed.biomedcentral.com/articles/10.1186/s13049-020-00791-0>. doi: 10.1186/s13049-020-00791-0.
- Ribeiro ALP, Paixão GMM, Gomes PR, Ribeiro MH, Ribeiro AH, Canazart JA, et al. Tele-electrocardiography and bigdata: The CODE (Clinical Outcomes in Digital Electrocardiography) study. *J Electrocardiol.* 2019;57S:S75-S78. <https://pubmed.ncbi.nlm.nih.gov/31526573/> doi: 10.1016/j.jelectrocard.2019.09.008.
- Alkmim MB, Figueira RM, Marcolino MS, Cardoso CS, Pena de Abreu M, Cunha LR, et al. Improving patient access to specialized health care: the Telehealth Network of Minas Gerais, Brazil. *Bull World Health Organ.* 2012;90(5):373-8. <https://pubmed.ncbi.nlm.nih.gov/22589571/> doi: 10.2471/BLT.11.099408.
- Attia ZI, Kapa S, Lopez-Jimenez F, McKie PM, Ladewig DJ, Satam G, et al. Screening for cardiac contractile dysfunction using an artificial intelligence-enabled electrocardiogram. *Nat Med.* 2019;25(1):70-4. <https://pubmed.ncbi.nlm.nih.gov/30617318/> doi: 10.1038/s41591-018-0240-2.
- Kwon JM, Cho Y, Jeon KH, Cho S, Kim KH, Baek SD, et al. A deep learning algorithm to detect anaemia with ECGs: a retrospective, multicentre study. *Lancet Digit Health.* 2020;2(7):e358-e367. <https://pubmed.ncbi.nlm.nih.gov/33328095/>. doi: 10.1016/S2589-7500(20)30108-4. Epub 2020 Jun 23. PMID: 33328095.
- Adedinsewo D, Carter RE, Attia Z, Johnson P, Kashou AH, Dugan JL, et al. Artificial Intelligence-Enabled ECG Algorithm to Identify Patients With Left Ventricular Systolic Dysfunction Presenting to the Emergency Department With Dyspnea. *Circ Arrhythm Electrophysiol.* 2020;13(8):e008437. <https://pubmed.ncbi.nlm.nih.gov/32986471/>doi: 10.1161/CIRCEP.120.008437. Epub 2020 Aug 4. PMID: 32986471.
- FDA. Emergency use of the ELECT during the COVID-19 pandemic.2020. <https://www.fda.gov/media/137930/download>.
- Cohen-Shelly M, Attia ZI, Friedman PA, Ito S, Essayagh BA, Ko WY, et al. Electrocardiogram screening for aortic valve stenosis using artificial intelligence. *Eur Heart J.* 2021;42(30):2885-96. doi: 10.1093/eurheartj/ehab153. <https://pubmed.ncbi.nlm.nih.gov/33748852/>



20. Kwon J-M, Jung M-S, Kim K-H, Jo Y-Y, Shin J-H, Cho Y-H, et al. Artificial intelligence for detecting electrolyte imbalance using electrocardiography. *Ann Noninvasive Electrocardiol*. 2021;26(3):e12839. doi: 10.1111/anec.12839. <https://pubmed.ncbi.nlm.nih.gov/33719135/>
21. Galloway CD, Valys AV, Shreibati JB, Treiman DL, Petterson FL, Gundotra VP, et al. Development and Validation of a Deep-Learning Model to Screen for Hyperkalemia From the Electrocardiogram. *JAMA Cardiol*. 2019;4(5):428-36. <https://pubmed.ncbi.nlm.nih.gov/30942845/>
22. Attia ZI, Sugrue A, Asirvatham SJ, Ackerman MJ, Kapa S, Friedman PA, et al. Noninvasive assessment of dofetilide plasma concentration using a deep learning (neural network) analysis of the surface electrocardiogram: A proof of concept study. *PLoS One*. 2018;13(8):e0201059. doi: 10.1371/journal.pone.0201059. <https://pubmed.ncbi.nlm.nih.gov/30133452/>
23. Kwon S, Hong J, Choi EK, Lee E, Hostallero DE, Kang WJ, et al. Deep Learning Approaches to Detect Atrial Fibrillation Using Photoplethysmographic Signals: Algorithms Development Study. *JMIR Mhealth Uhealth*. 2019;7(6):e12770. doi: 10.2196/12770. <https://pubmed.ncbi.nlm.nih.gov/31199302/>
24. Han L, Askari M, Altman RB, Schmitt SK, Fan J, Bentley JP, et al. Atrial Fibrillation Burden Signature and Near-Term Prediction of Stroke: A Machine Learning Analysis. *Circ Cardiovasc Qual Outcomes*. 2019;12(10):e005595. doi: 10.1161/CIRCOUTCOMES.118.005595. <https://pubmed.ncbi.nlm.nih.gov/31610712/>
25. Dewland TA, Vittinghoff E, Mandyam MC, Heckbert SR, Siscovick DS, Stein PK, et al. Atrial ectopy as a predictor of incident atrial fibrillation: a cohort study. *Ann Intern Med*. 2013;159(11):721-8. doi: 10.7326/0003-4819-159-11-201312030-00004. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4115459/>
26. Lip GY, Nieuwlaat R, Pisters R, Lane DA, Crijns HJ. Refining clinical risk stratification for predicting stroke and thromboembolism in atrial fibrillation using a novel risk factor-based approach: the Euro Heart Survey on atrial fibrillation. *Chest*. 2010;137(2): 263–72. <https://pubmed.ncbi.nlm.nih.gov/19762550/>
27. Taniguchi H, Takata T, Takechi M, Furukawa A, Iwasawa J, Kawamura A, et al. Explainable Artificial Intelligence Model for Diagnosis of Atrial Fibrillation Using Holter Electrocardiogram Waveforms. *Int Heart J*. 2021;62(3):534-9. doi: 10.1536/ihj.21-094. <https://pubmed.ncbi.nlm.nih.gov/34053998/>
28. Attia ZI, Noseworthy PA, Lopez-Jimenez F, Asirvatham SJ, Deshmukh AJ, Gersh BJ, et al. An artificial intelligence-enabled ECG algorithm for the identification of patients with atrial fibrillation during sinus rhythm: a retrospective analysis of outcome prediction. *Lancet*. 2019;394(10201):861-7. doi: 10.1016/S0140-6736(19)31721-0. <https://pubmed.ncbi.nlm.nih.gov/31378392/>
29. Santala OE, Halonen J, Martikainen S, Jäntti H, Rissanen TT, Tarvainen MP, et al. Automatic Mobile Health Arrhythmia Monitoring for the Detection of Atrial Fibrillation: Prospective Feasibility, Accuracy, and User Experience Study. *JMIR Mhealth Uhealth*. 2021;9(10):e29933. doi: 10.2196/29933. <https://pubmed.ncbi.nlm.nih.gov/34677135/>
30. Pandit JA, Lores E, Battie D. Cuffless Blood Pressure Monitoring: Promises and Challenges. *Clin J Am Soc Nephrol*. 2020;15(10):1531-38. doi: 10.2215/CJN.03680320. <https://pubmed.ncbi.nlm.nih.gov/32680913/>
31. Agliari E, Barra A, Barra OA, Fachechi A, Vento LF, Moretti L. Detecting cardiac pathologies via machine learning on heart-rate variability time series and related markers. *Sci Rep*. 2020;10(1):8845. doi: 10.1038/s41598-020-64083-4. <https://pubmed.ncbi.nlm.nih.gov/32483156/>
32. Persell SD, Peparah YA, Lipiszko D, Lee JY, Li JJ, Ciolino JD, et al. Effect of Home Blood Pressure Monitoring via a Smartphone Hypertension Coaching Application or Tracking Application on Adults With Uncontrolled Hypertension: A Randomized Clinical Trial. *JAMA Netw Open*. 2020;3(3):e200255. doi: 10.1001/jamanetworkopen.2020.0255. <https://pubmed.ncbi.nlm.nih.gov/32119093/>

# INTELIGÊNCIA ARTIFICIAL EM CARDIOLOGIA INTERVENZIONISTA

## ARTIFICIAL INTELLIGENCE IN INTERVENTIONAL CARDIOLOGY

### RESUMO

Inteligência artificial é uma denominação ampla, que remete a tecnologias computacionais que objetivam mimetizar o comportamento, ações, cognição e/ou inteligência humanas com um mínimo de intervenção de operadores humanos. A cardiologia intervencionista é um dos ramos da medicina cardiovascular que mais se desenvolveu nas últimas décadas, apresentando um conjunto altamente tecnológico que perfaz um campo propício à incorporação de métodos de inteligência artificial. A cardiologia intervencionista pode ser incrementada por inteligência artificial através de duas principais vertentes: virtual e física. Atualmente e para o futuro próximo, diversos relatos têm demonstrado o surgimento progressivo de tecnologias derivadas de inteligência artificial para ampliar a prática da cardiologia intervencionista no diagnóstico e tratamento de doenças coronárias, intervenções estruturais e a moderna incorporação de braços robóticos.

**Descritores:** Inteligência Artificial; Cateterismo Cardíaco; Angioplastia; Cardiologia

### ABSTRACT

*Artificial intelligence is broad term that relates to computational technologies that aim to imitate human behavior, actions, cognition, and/or intelligence with minimal human intervention. Interventional cardiology is one of the branches of cardiovascular medicine that has developed the most in recent decades, presenting a highly technological environment conducive to the incorporation of methods based on artificial intelligence. Interventional cardiology can be enhanced by artificial intelligence through two main aspects: virtual and physical. Currently and for the near future, several reports have demonstrated the progressive emergence of technologies derived from artificial intelligence and used to expand the practice of interventional cardiology for the diagnosis and treatment of coronary artery disease, structural interventions, and the modern incorporation of robotic arms.*

**Keywords:** Artificial Intelligence; Cardiac Catheterization; Angioplasty; Cardiology.

Pedro A. Lemos <sup>1,2</sup>

1. Hospital Israelita Albert Einstein,  
São Paulo, SP, Brasil  
2. Instituto do Coração (InCor),  
Faculdade de Medicina da  
Universidade de São Paulo, SP, Brasil

Correspondência  
Pedro A. Lemos  
pedro.lemos@atscien.com

## INTRODUÇÃO

Inteligência artificial é uma denominação ampla, que remete a tecnologias computacionais que objetivam mimetizar o comportamento, ações, cognição e/ou inteligência humanas com um mínimo de intervenção de operadores humanos. Inteligência artificial engloba um espectro de técnicas, em franca expansão, que incluem, dentre outras, *machine learning*, *deep learning*, processamento de linguagem natural (*natural language processing*), computação cognitiva (*cognitive computing*), visão computacional (*computer vision*) e robótica, empregadas para integrar, relacionar, interpretar, simular dados complexos.<sup>1</sup> Para fins de simplificação, no presente artigo de revisão, usaremos o termo "inteligência artificial" de modo genérico, representativo do conjunto descrito acima.

A cardiologia intervencionista é um dos ramos da medicina cardiovascular que mais se desenvolveu nas

últimas décadas, e hoje compreende um amplo espectro de possibilidades diagnósticas e terapêuticas, largamente utilizadas em laboratórios de cateterismo cardíaco em todas as partes do mundo. Apesar de diversas, as técnicas da cardiologia intervencionista apresentam alguns pontos em comum entre si, sendo sempre baseadas em cateteres, dependentes de métodos de imagem, e fortemente apoiadas em maquinário computadorizado sofisticado. Note-se ainda que, além do conjunto de suas próprias ações, é ampla a interdependência da cardiologia intervencionista com métodos não-invasivos de imagem, antes, durante e depois do ato intervencionista.

O conjunto altamente tecnológico envolvido na prática da cardiologia intervencionista leva a um campo propício para a incorporação potencial de métodos de inteligência artificial. O presente artigo objetiva revisar aplicações da inteligência artificial na cardiologia intervencionista atual.

## INTELIGÊNCIA ARTIFICIAL E CARDIOLOGIA INTERVENCIONISTA

A prática da cardiologia intervencionista pode ser incrementada por inteligência artificial através de duas principais vertentes atuais: virtual e física.<sup>1</sup> As disciplinas “virtuais” remetem, por exemplo, a aplicações relacionadas a sistemas de gerenciamento (p.e. informações em prontuários e registros eletrônicos, software para análise de imagens médicas [nativos no próprio equipamento de aquisição de imagem, ou para aplicação posterior]), ou a sistemas de auxílio a decisão médica. Um exemplo característico do ramo “físico” seria a aplicação de técnicas de robótica à cardiologia intervencionista.

### Doença Coronária

Diferentes estudos têm descrito o surgimento de técnicas de inteligência artificial desenvolvidas para incrementar os métodos diagnósticos intervencionistas para a doença coronária. Apesar de alguns resultados ainda mostrarem-se heterogêneos e iniciais, essas iniciativas demonstram o potencial desse campo do conhecimento. Abaixo, uma lista de desenvolvimentos recentemente relatados pelo nosso grupo<sup>2,3</sup> e por outros investigadores:

- Determinação dos limites da luz vascular e da lâmina elástica externa, e seleção da fase do ciclo cardíaco, em imagens de ultrassom intravascular.<sup>2-5</sup>
- Identificação automática de estenoses significativas em imagens de angiografia coronária.<sup>6</sup>
- Classificação do tipo morfológico de placa aterosclerótica a partir de imagens de tomografia de coerência óptica<sup>7,8</sup> e de ultrassom intravascular.<sup>9,10</sup>
- Predição dos resultados do implante de *stent* com base em imagens de ultrassom intravascular pré-intervenção.<sup>11</sup>
- Cálculo automático da reserva fracionada de fluxo (FFR) com base em imagens de angiografia coronária<sup>12</sup> e de ultrassom intravascular.<sup>13</sup>
- Segmentação coronária e identificação da fase do ciclo cardíaco a partir de imagens angiográficas.<sup>14-16</sup>

A avaliação da necessidade de revascularização miocárdica, bem como o melhor método a ser aplicado (i.e. cirúrgico ou percutâneo), é uma das áreas de mais intensa investigação científica na medicina cardiovascular. Apesar disso, a indicação do tratamento invasivo persiste envolta por uma série de incertezas. Um dos aspectos de variabilidade considerável é a interpretação de testes de avaliação invasiva e não-invasiva da fisiologia e da morfologia coronária, cuja inconsistência pode ser potencialmente reduzida pela utilização de inteligência artificial.<sup>17,18</sup>

Um estudo recente avaliou a interpretação de 15 especialistas humanos isoladamente e em consenso (*Heart Team*) sobre 1.008 traçados de fluxo coronário não-hiperêmico (IFR), comparativamente à análise de um algoritmo de inteligência artificial. A concordância da indicação de angioplastia entre os especialistas e o *Heart Team* foi de 89,3%, enquanto a decisão por inteligência artificial coincidiu com a do *Heart Team* em 89,4% ( $p < 0.01$  para não-inferioridade). Interessantemente, quando se testou a reprodutibilidade da opinião do *Heart Team*, sua decisão mudou-se em uma a cada dez vezes, ao passo que a estratégia decidida pelo algoritmo não se alterou nenhuma vez.<sup>19</sup>

### Intervenção Cardíaca Estrutural

Atualmente, dispomos na prática intervencionista de um amplo arsenal de dispositivos capazes de modificar terapêuticamente a morfologia do coração, configurando-se um conjunto que chamamos de “intervenções cardíacas estruturais”. Fazem parte desse grupo os implantes por cateter de prótese valvar aórtica e ou prótese valvar mitral, clipagem valvar mitral, as valvoplastias por balão, a oclusão do apêndice atrial esquerdo, as oclusões de *leaks* paravalvares e a oclusão de comunicações inter-cavitárias, dentre outros. O planejamento pré-procedimento é parte fundamental e integral do fluxo de avaliação para intervenções cardíacas estruturais. Para isso, são utilizados métodos diagnósticos invasivos (p.e. angiografia invasiva, manometria intravascular) e não-invasivos (p.e. angiotomografia, ecocardiografia, ressonância nuclear magnética, ECG, dentre outros) como ferramentas para estimar o grau de sucesso da intervenção, bem como definir a melhor estratégia intervencionista a ser empregada. Recentemente, foi relatado que técnicas de inteligência artificial aplicadas a imagens de angiotomografia foram capazes de melhor classificar a necessidade de angiografia invasiva em candidatos ao implante por cateter de bioprótese valvar aórtica.<sup>20</sup> Também utilizando imagens de angiotomografia, algoritmos de inteligência artificial têm sido desenvolvidos para simular o implante de bioprótese valvar aórtica com o intuito de auxiliar operadores na escolha do tipo e tamanho da prótese, bem como selecionar a melhor profundidade na via de saída do ventrículo esquerdo para realizar a sua liberação.<sup>21</sup>

Alguns estudos têm explorado o potencial da inteligência artificial na predição do prognóstico após intervenções valvares. Os resultados iniciais disponíveis até o momento demonstram que algoritmos derivados de técnicas de inteligência artificial são capazes de prever a ocorrência de eventos combinados,<sup>22</sup> óbito,<sup>23,24</sup> sangramentos maiores,<sup>25,26</sup> necessidade de marcapasso definitivo<sup>27</sup> após o implante transcatheter de bioprótese valvar aórtica.

O treinamento de novos intervencionistas, bem como o treinamento em novos procedimentos de intervencionistas experientes, é uma das áreas mais desafiadoras da cardiologia intervencionista atual, particularmente no campo das intervenções estruturais, onde a curva de aprendizado pode ser mais longa e o volume de casos menor. A utilização de abordagens modernas de simulação por inteligência artificial, modelagem computacional e impressão 3D têm modificado o cenário de capacitação profissional, devendo ser amplamente incorporada no futuro como parte integrante do dia-a-dia dos operadores envolvidos em intervenções estruturais.<sup>28</sup>

### Intervenção Cardíaca Robótica

A intervenção cardíaca robótica, recentemente introduzida na prática norte-americana, europeia, japonesa e no Brasil,<sup>29</sup> permite ao operador manipular os instrumentos intervencionistas através de braço robótico montado na lateral da mesa de procedimento, controlado a partir de uma estação de controle com proteção blindada contra radiação, localizada fora da sala de cateterismo. Nos modelos atuais, o braço é eletronicamente conectado via cabo à cabine de comando intervencionista, na qual o operador se senta e controla *joysticks* e *touch screens* que dirigem os dispositivos

terapêuticos. Atualmente, os sistemas robóticos disponíveis para uso rotineiro não apresentam automatismo baseado em sistemas de inteligência artificial, apesar de esta ser uma implementação natural esperada para o futuro das próximas gerações de robô.<sup>1</sup>

## CONCLUSÃO

Tecnologias desenvolvidas a partir de inteligência artificial têm sido progressivamente incorporadas a diversas e diferentes aplicações em cardiologia intervencionista,

desde angioplastia coronária até intervenções estruturais e robóticas, auxiliando na predição de risco, na acurácia diagnóstica, na escolha da estratégia intervencionista e no treinamento profissional.

## CONFLITOS DE INTERESSE

Os autores declaram não possuir conflitos de interesse na realização deste trabalho.

## REFERÊNCIAS

- Sardar P, Abbott JD, Kundu A, Aronow HD, Granada JF, Giri J. Impact of Artificial Intelligence on Interventional Cardiology: From Decision-Making Aid to Advanced Interventional Procedure Assistance. *JACC Cardiovasc Interv.* 2019;12(14):1293-303.
- Blanco PJ, Ziemer PGP, Bulant CA, Ueki Y, Bass R, Raber L, et al. Fully automated lumen and vessel contour segmentation in intravascular ultrasound datasets. *Med Image Anal.* 2022;75:102262.
- Ziemer PGP, Bulant CA, Orlando JO, Talou GD, Alvarez LAM, Bezerra CG, Lemos PA, et al. Automation of lumen segmentation using multi-frame convolutional neural networks in intravascular ultrasound datasets. *Eur Heart J – Digital Health.* 2020;1:75-82.
- Bajaj R, Huang X, Kilic Y, Ramasamy A, Jain A, Ozkor M, et al. Advanced deep learning methodology for accurate, real-time segmentation of high-resolution intravascular ultrasound images. *Int J Cardiol.* 2021;339:185-191.
- Bajaj R, Huang X, Kilic Y, Jain A, Ramasamy A, Torii R, et al. A deep learning methodology for the automated detection of end-diastolic frames in intravascular ultrasound images. *Int J Cardiovasc Imaging.* 2021;37(6):1825-37.
- Yabushita H, Goto S, Nakamura S, Oka H, Nakayama M, Goto S. Development of Novel Artificial Intelligence to Detect the Presence of Clinically Meaningful Coronary Atherosclerotic Stenosis in Major Branch from Coronary Angiography Video. *J Atheroscler Thromb.* 2021;28(8):835-43.
- Shibutani H, Fujii K, Ueda D, Kawakami R, Imanaka T, Kawai K, et al. Automated classification of coronary atherosclerotic plaque in optical frequency domain imaging based on deep learning. *Atherosclerosis.* 2021;328:100-5.
- Min HS, Yoo JH, Kang SJ, Lee JG, Cho H, Lee PH, et al. Detection of optical coherence tomography-defined thin-cap fibroatheroma in the coronary artery using deep learning. *EuroIntervention.* 2020;16(5):404-12.
- Cho H, Kang SJ, Min HS, Lee JG, Kim WJ, Kang SH, et al. Intravascular ultrasound-based deep learning for plaque characterization in coronary artery disease. *Atherosclerosis.* 2021;324:69-75.
- Bae Y, Kang SJ, Kim G, Lee JG, Min HS, Cho H, Kang DY, Lee PH, Ahn JM, Park DW, Lee SW, Kim YH, Lee CW, Park SW and Park SJ. Prediction of coronary thin-cap fibroatheroma by intravascular ultrasound-based machine learning. *Atherosclerosis.* 2019;288:168-74.
- Min HS, Ryu D, Kang SJ, Lee JG, Yoo JH, Cho H, et al. Prediction of Coronary Stent Underexpansion by Pre-Procedural Intravascular Ultrasound-Based Deep Learning. *JACC Cardiovasc Interv.* 2021;14(9):1021-9.
- Roguin A, Abu Dogosh A, Feld Y, Konigstein M, Lerman A, Koifman E. Early Feasibility of Automated Artificial Intelligence Angiography Based Fractional Flow Reserve Estimation. *Am J Cardiol.* 2021;139:8-14.
- Lee JG, Ko J, Hae H, Kang SJ, Kang DY, Lee PH, et al. Intravascular ultrasound-based machine learning for predicting fractional flow reserve in intermediate coronary artery lesions. *Atherosclerosis.* 2020;292:171-77.
- Wang L, Liang D, Yin X, Qiu J, Yang Z, Xing J, et al. Coronary artery segmentation in angiographic videos utilizing spatial-temporal information. *BMC Med Imaging.* 2020;20(1):110.
- Ciusdel C, Turcea A, Puiu A, Itu L, Calmac L, Weiss E, et al. Deep neural networks for ECG-free cardiac phase and end-diastolic frame detection on coronary angiographies. *Comput Med Imaging Graph.* 2020;84:101749.
- Liang D, Qiu J, Wang L, Yin X, Xing J, Yang Z, et al. Coronary angiography video segmentation method for assisting cardiovascular disease interventional treatment. *BMC Med Imaging.* 2020;20(1):65.
- Seetharam K, Shrestha S, Sengupta PP. Cardiovascular Imaging and Intervention Through the Lens of Artificial Intelligence. *Interv Cardiol.* 2021;16:e31.
- Koo BK, Samady H. Strap In for the Artificial Intelligence Revolution in Interventional Cardiology. *JACC Cardiovasc Interv.* 2019;12(14):1325-27.
- Cook CM, Warisawa T, Howard JP, Keeble TR, Iglesias JF, Schampaert E, et al. Algorithmic Versus Expert Human Interpretation of Instantaneous Wave-Free Ratio Coronary Pressure-Wire Pull Back Data. *JACC Cardiovasc Interv.* 2019;12(14):1315-24.
- Gohmann RF, Pawelka K, Seitz P, Majunke N, Heiser L, Renatus K, Desch S, et al. Combined Coronary CT-Angiography and TAVR Planning for Ruling Out Significant Coronary Artery Disease: Added Value of Machine-Learning-Based CT-FFR. *JACC Cardiovasc Imaging.* 2021;S1936-878X(21)00697-5.
- El Faquir N, De Backer O, Bosmans J, Rudolph T, Buzzatti N, Bieliauskas G, et al. Patient-Specific Computer Simulation in TAVR With the Self-Expanding Evolut R Valve. *JACC Cardiovasc Interv.* 2020;13(15):1803-12.
- Gomes B, Pilz M, Reich C, Leuschner F, Konstandin M, Katus HA, et al. Machine learning-based risk prediction of intrahospital clinical outcomes in patients undergoing TAVI. *Clin Res Cardiol.* 2021;110(3):343-56.
- Penso M, Pepi M, Fusini L, Muratori M, Cefalu C, Mantegazza V, et al. Predicting Long-Term Mortality in TAVI Patients Using Machine Learning Techniques. *J Cardiovasc Dev Dis.* 2021;8(4):44..
- Agasthi P, Ashraf H, Pujari SH, Girardo ME, Tseng A, Mookadam F, et al. Artificial Intelligence Trumps TAVI2-SCORE and CoreValve Score in Predicting 1-Year Mortality Post-Transcatheter Aortic Valve

---

Replacement. *Cardiovasc Revasc Med.* 2021;24:33-41.

25. Jia Y, Luosang G, Li Y, Wang J, Li P, Xiong T, et al. Deep Learning in Prediction of Late Major Bleeding After Transcatheter Aortic Valve Replacement. *Clin Epidemiol.* 2022;14:9-20.
26. Navarese EP, Zhang Z, Kubica J, Andreotti F, Farinaccio A, Bartorelli AL, et al. Development and Validation of a Practical Model to Identify Patients at Risk of Bleeding After TAVR. *JACC Cardiovasc Interv.* 2021;14(11):1196-206.
27. Truong VT, Beyerbach D, Mazur W, Wigle M, Bateman E, Pallerla A, et al. Machine learning method for predicting pacemaker implantation following transcatheter aortic valve replacement. *Pacing Clin Electrophysiol.* 2021;44(2):334-40.
28. Wang DD, Qian Z, Vukicevic M, Engelhardt S, Kheradvar A, Zhang C, et al. 3D Printing, Computational Modeling, and Artificial Intelligence for Structural Heart Disease. *JACC Cardiovasc Imaging.* 2021;14(1):41-60.
29. Lemos PA, Franken M, Mariani J, Jr., Pitta FG, Oliveira FA, Cunha-Lima G, et al. Use of robotic assistance to reduce proximity and air-sharing during percutaneous cardiovascular intervention. *Future Cardiol.* 2021;17(5):865-73.

# INTELIGÊNCIA ARTIFICIAL EM CIRURGIA CARDIOVASCULAR

## ARTIFICIAL INTELLIGENCE IN CARDIOVASCULAR SURGERY

Omar Asdrubal Vilca Mejia<sup>1</sup>  
Luis Roberto Palma Dallan<sup>1</sup>

1. Instituto do Coração, Hospital das Clínicas HCFMUSP. Universidade de São Paulo. Faculdade de Medicina. Departamento de Cirurgia Cardiovascular. São Paulo, SP, Brasil.

Correspondência  
Omar Asdrubal Vilca Mejia  
omar.mejia@incor.usp.br.

### RESUMO

A inteligência artificial (IA) não se destina a substituir o médico, mas sim, a criar um fluxo de trabalho eficiente, ensejando tempo para as relações médico-paciente. No cenário em que o cirurgião e o paciente devem permanecer no centro da tomada de decisão, a IA proporciona um suporte de precisão para a tomada de decisão médica. Isso ocorre por meio da integração de diversas fontes de informação como fatores de risco do paciente, anatomia cardíaca, história natural da doença e custos hospitalares. Na cirurgia cardíaca, a inteligência artificial pode ser usada em três áreas principais: predição de risco cirúrgico, exames de imagem e realidade aumentada na sala de cirurgia. O sistema IA tem uma variedade de configurações/formulações, que vão desde aquelas que buscam responder um problema usando grandes conjuntos de dados, de modo a gerar uma estrutura nos moldes do raciocínio humano, até aqueles que tentam incorporar elementos do raciocínio humano, mas não exigem modelagem precisa dos processos humanos. Um dos braços da IA é o aprendizado de máquina (AM), que corresponde a técnicas de modelagem estatística e matemática que usam uma variedade de abordagens para aprender e melhorar automaticamente a previsão de um desfecho, sem programação explícita. Assim, redes bayesianas, *random forest*, *deep learning* e redes neurais artificiais, usam diferentes suposições e estruturas matemáticas para entrada de dados, e o aprendizado ocorre dentro do algoritmo.

**Descritores:** Cirurgia Cardiovascular; Inteligência Artificial; Tomada de Decisões.

### ABSTRACT

*Artificial intelligence (AI) is not intended to replace the physician, but to create an efficient workflow, freeing up time for doctor-patient relationships. In the scenario where the surgeon and the patient must remain at the center of decision-making, AI provides precision support for medical decision-making. This occurs through the integration of diverse sources of information, such as patient risk factors, cardiac anatomy, natural history of the disease, and hospital costs. In cardiac surgery, artificial intelligence can be used in three key areas: surgical risk prediction, imaging exams, and augmented reality in the operating room. The AI system has a variety of configurations/formulations, ranging from those that seek to solve a problem using large datasets to generate a structure modeled on human reasoning to those that attempt to incorporate elements of human reasoning but do not require precise modeling of human processes. One of the branches of AI is machine learning (ML), which corresponds to statistical and mathematical modeling techniques that use a variety of methods to automatically learn and improve the prediction of an outcome, without explicit programming. Thus, Bayesian networks, random forest, deep learning, and artificial neural networks use different assumptions and mathematical structures for data entry, and the learning occurs inside the algorithm.*

**Keywords:** Cardiovascular Surgery; Artificial Intelligence; Clinical Decision-Making.

### PREDIÇÕES DE RISCO

Um dos grandes desafios existentes é na tomada de decisão em cirurgia pois é muito variável e influenciada por um raciocínio dedutivo hipotético e julgamento pessoal.<sup>1</sup>

Para ajudar na tomada de decisões, foram criados os escores de risco. Esses escores fazem previsões de resultados clínicos e são úteis para a tomada de

decisões, pois preveem eventos como o risco de complicações e morte.

Os modelos mais usados atualmente são os de regressão linear. Eles usam variáveis (fatores de risco) pré-selecionadas pela significância clínica e escolhidas através de técnicas estatísticas pela sua relação linear com o desfecho analisado.

No entanto, estas técnicas são enviesadas uma vez que

limitam a capacidade de uso de outras variáveis clínicas que poderiam auxiliar na predição de resultados.<sup>2</sup>

A IA pode superar estes modelos integrando muitas variáveis de várias fontes de dados envolvendo o rastreamento dos gestos do cirurgião e movimento das mãos para extrair métricas objetivas de habilidades psicomotoras técnicas.<sup>3</sup>

Em cirurgia cardiovascular, foram desenvolvidos algoritmos de aprendizado de máquina que podem superar os escores de risco operatório tradicionais na predição de mortalidade após cirurgia cardíaca.<sup>4</sup>

No nosso meio a predição de risco de mortalidade em cirurgia cardíaca começou no início da década passada com a validação de escores de risco internacionais e a formulação de modelos locais utilizando técnicas de regressão logística e *bootstrap*.<sup>5</sup>

Já em 2018, através banco de dados de quase 3000 pacientes portadores de cardiopatia reumática submetidos a cirurgia valvar foi criado um modelo de IA para análise de risco, chamado RheSCORE.<sup>6</sup> Esse escore teve seu desempenho comparado ao 2000 Bernstein-Parsonnet, EuroSCORE II, InCor, AmblerSCORE, GuaragnaSCORE e New York SCORE. O RheSCORE foi criado com *random forest* e obteve uma acurácia de 0,98 superior aos outros modelos na predição de mortalidade após cirurgia valvar.

Em 2020 um modelo de risco para prever mortalidade após cirurgia congênita também foi criado com IA a partir de um registro com 2240 pacientes. Novamente um modelo criado com *random forest* alcançou uma acurácia de 0,9.<sup>7</sup>

No mesmo ano o SPScore, um modelo construído com *random forest*, foi derivado de 5222 pacientes provenientes de 11 hospitais do estado de São Paulo que fazem parte do Registro Paulista de Cirurgia Cardiovascular (REPLICCAR). O SPScore foi comparado com o STS e com o EuroSCORE, que são os modelos de risco mais conhecidos do mundo na predição do risco de mortalidade, morbidade, reoperação e reinternação após cirurgia cardíaca. O desempenho do SPScore foi superior aos modelos tradicionais tornando-se uma proposta custo efetiva na implementação de melhorias de qualidade.<sup>8</sup>

Um estudo publicado recentemente testou o desempenho da IA na previsão de mortalidade um ano após o procedimento de TAVI (implante valvar aórtico transcaterter). Este modelo foi superior ao TAVI2-SCORE e CoreValve SCORE, que são dois modelos tradicionais de predição de risco nesse tipo de procedimento.<sup>9</sup>

Não apenas a acurácia do modelo inteligência artificial foi boa, como identificou algumas variáveis preditoras de mortalidade que não são habitualmente associados a esse desfecho nos modelos tradicionais.

Esses modelos de escore de risco pré-operatório baseados em inteligência artificial tem um futuro promissor, mas que ainda depende de alguns fatores. Para que ocorra uma disseminação do seu uso, algumas barreiras têm que ser superadas. A primeira é a criação e a testagem dos modelos em estudos prospectivos comparando esse modelo, com os usados tradicionalmente.

Um outro ponto a ser superado é a criação de algoritmos que consigam captar os dados dos prontuários eletrônicos dos pacientes de forma independente e automática, sem a necessidade de alimentação por equipes de pesquisa.

Esse seria um avanço importante que depende da integração da plataforma de dados presente nos hospitais com os softwares de IA que fazer a captura dos dados.<sup>10</sup>

## REALIDADE AUMENTADA

Uma das aplicações mais esperadas da inteligência artificial em cirurgia cardíaca são na realidade aumentada intraoperatória e na robótica. A realidade aumentada permite a integração de imagens médicas com procedimentos cirúrgicos em tempo real.

Estamos presenciando um grande avanço na automação dos exames de imagem pré-operatórios como tomografia computadorizada, ecocardiograma e ressonância nuclear magnética. Existem aplicações em procedimentos endovasculares, como o TAVR ou o Mitraclip.<sup>11</sup> Usando a parede do vaso como guia, um cateter robô pode navegar e colocar um dispositivo de oclusão para vazamento perivalvar aórtico em modelo porcino. O resultado não foi inferior ao desempenho humano manual.

Especificamente em cirurgias de aorta, alguns grupos têm trabalhado em modelos de IA para tentar prever possíveis complicações pós-operatórias. Um grupo testou modelos para avaliar o risco de insuficiência renal e paraplegia em pacientes submetidos à cirurgia toracoabdominal. Outro avaliou se a associação de parâmetros clínicos e com exames de imagem poderiam prever o aumento do diâmetro da aorta após implante de stent para o tratamento de dissecção tipo B.

Recentemente em uma rara cirurgia de separação de gêmeas siamesas, a unidade cirúrgica de cardiopatia congênitas do InCor utilizando reconstrução tomográfica dos corações e com o auxílio dos óculos de realidade virtual em 3D, visualizaram o ponto de conexão dos órgãos e desenharam o plano cirúrgico. A partir disto, várias simulações pré-cirúrgicas culminaram com o sucesso do resultado.

A IA e a robótica estão no horizonte para serem implementadas na prática. No entanto, semelhante aos veículos autônomos, há preocupações em relação à responsabilidade e culpabilidade quando a IA comete erros. Atualmente, os cirurgiões são inteiramente responsáveis por todas as ações que os robôs realizam, uma vez que eles não realizam nenhuma tarefa autônoma ou aprendida.

A primeira tarefa autônoma de sutura simples foi bem executada pelo *Smart Tissue Autonomous Robot* (STAR). Ele foi capaz de realizar uma sutura linear contínua em uma anastomose de intestino delgado porcino sem complicações em sete dias.<sup>12</sup>

A tecnologia robótica caminha para mudar as características da cirurgia. A complexidade dessas tarefas também está mudando dos primeiros robôs de automação de baixo nível para recursos autônomos de alto nível, como manobras cirúrgicas endoscópicas complexas e abordagens de controle compartilhado em cirurgia de coração batendo guiada por imagem estabilizada.

Espera-se que o uso de robôs se torne a modalidade padrão para a maioria dos procedimentos cirúrgicos, incluindo cirurgias de revascularização miocárdica e cirurgia abdominal. O futuro da IA na robótica está mais provavelmente na cirurgia robótica assistida por inteligência artificial, em oposição aos robôs totalmente autônomos.<sup>13</sup>

Por outro lado, a instrumentação com IA para cirurgia

assistida por robótica é objeto de intensa investigação. Para o aprendizado de habilidades cirúrgicas utilizando as técnicas de IA, o conhecimento especializado é normalmente fornecido por cirurgiões experientes. O aprendizado por imitação implícita é uma forma de aprendizado supervisionado, que geralmente se preocupa em acelerar o aprendizado reforçado por meio da observação de um mentor especialista. Vários métodos desenvolvidos para modelar o movimento humano podem ser utilizados para aprender as mesmas ações do especialista.<sup>14</sup>

## A MELHORA DO DESEMPENHO HUMANO

### Ciência de dados cirúrgicos

Com o surgimento de novas tecnologias e sua incorporação na sala cirúrgica, junto à enorme quantidade de dados gerados pelo atendimento dos pacientes, uma nova área denominada a ciência de dados cirúrgicos (CDC) está sendo criada. Ela tem o objetivo de melhorar a qualidade dos cuidados cirúrgicos, capturando, organizando, processando e modelando dados.<sup>15</sup>

Na CDC, dados surgem de diferentes fontes como monitorização do paciente e do procedimento, dos especialistas envolvidos nos cuidados e do conhecimento sobre o tema. Com base nisso, aplicações promissoras de IA foram desenvolvidas com o objetivo de apoiar as tomadas de decisões cirúrgicas e melhorar a segurança do paciente.<sup>16</sup>

Um bom exemplo é o sistema de caixa preta da sala de cirurgias.<sup>17</sup> Essa plataforma analítica permite a captura e integração de uma ampla variedade de dados intraoperatórios (por exemplo, áudio, vídeo, parâmetros fisiológicos), permitindo métricas baseadas em humanos e IA. Estudos recentes vêm utilizando essa plataforma para investigar o desempenho técnico e não técnico, e, sua relação com os resultados cirúrgicos dos pacientes.<sup>18,19</sup>

Mais recentemente, estudos conseguiram demonstrar a validade de algoritmos de aprendizado de máquina na predição de complicações intraoperatórias precoces, como hipotensão e hipoxemia em cirurgias.<sup>20</sup>

Em Michigan nos Estados Unidos, existe um projeto piloto em andamento, no qual o cirurgião e sua equipe estão sendo monitorados por câmeras durante todo o procedimento. Além do registro por câmeras, a equipe cirúrgica possui monitorização da frequência cardíaca para avaliar momentos de estresse durante o ato e identificar o evento gatilho.<sup>21</sup> A filmagem da cirurgia é feita e a análise dos softwares de IA podem futuramente recomendar medidas para melhora do desempenho cirúrgico, como tipo de exposição do coração, posicionamento das mãos do cirurgião e do assistente e até o ângulo do porta agulhas para cada momento.

O uso da IA, especialmente na visão computacional, oferece uma oportunidade promissora para automatizar, padronizar e dimensionar a avaliação do desempenho em cirurgia cardiovascular.

### Aumento da cognição na sala de cirurgia

A cirurgia cardiovascular é um exemplo perfeito de como a IA pode ser usada para apoiar os cuidados cirúrgicos por meio do aumento cognitivo. A sala de cirurgia é um ambiente de alto risco, onde vários profissionais especializados

interagem entre si, coordenam tarefas em equipe e utilizam uma variedade de equipamentos, dispositivos tecnológicos e interfaces para atender efetivamente pacientes complexos que necessitam de tratamento cirúrgico.<sup>22</sup>

Funcionando como um complexo sistema de relacionamento social e técnico, a equipe realiza tarefas de forma coordenada exigindo habilidades cognitivas que estão além do desempenho individual de cada membro da equipe.

Como cada membro da equipe não tem controle sobre o desempenho da equipe como um todo, as atividades cognitivas são processos de trabalho em equipe e não tarefas individuais.<sup>23</sup>

O ambiente de trabalho na sala de cirurgia cardíaca incorporou tecnologia e, com isto, novos sistemas computacionais, visando otimizar processos e apoiar a equipe cirúrgica. Além de gerar uma enorme quantidade de dados, que podem ser usados para o desenvolvimento de modelos preditivos de IA, esse ambiente computacional complexo também permitiu o aumento da cognição humana em nível individual e de equipe.<sup>24</sup>

Desta forma a cognição é estendida para fora da mente dos indivíduos para toda a equipe cirúrgica, incorporando não apenas agentes humanos, mas também sistemas não humanos envolvidos.

Para monitorar estados cognitivos em nível individual e de equipe, métricas fisiológicas como variabilidade da frequência cardíaca (VFC), eletroencefalografia (EEG) e espectroscopia no infravermelho próximo (NIRS) são as mais utilizadas, pois permitem medidas objetivas em tempo real da carga cognitiva.<sup>25</sup>

### Visão computacional em cirurgia

À medida que os sistemas computacionais se tornam onipresentes e o nosso local de trabalho está cheio de dispositivos e redes computacionais, a comunicação e a coordenação cirúrgica precisam ser otimizadas.<sup>26</sup> No campo do reconhecimento da atividade humana, a visão computacional é um método promissor de IA que pode ser usado para segmentação de tarefas cirúrgicas e monitoramento da dinâmica da equipe.

Para abranger todos os avanços do uso da IA na melhoria da cognição em sala de cirurgia, foi criado recentemente um campo interdisciplinar chamado "cirurgia cognitiva" ou "cirurgia guiada pela cognição."<sup>27</sup>

A visão computacional é um ramo da IA que extrai e processa dados de imagens e vídeos e fornece à máquina a compreensão desses dados.<sup>28</sup> Em vários campos, as tecnologias de visão computacional são capazes de alcançar o desempenho humano e, em certos casos, até mesmo exceder as habilidades humanas.<sup>29,30</sup>

Na cirurgia, as principais aplicações da visão computacional estão relacionadas à segmentação do fluxo de trabalho cirúrgico<sup>31,32</sup> reconhecimento e detecção de instrumentos<sup>33</sup> e intervenções cirúrgicas guiadas por imagem.<sup>34</sup> No entanto, uma nova área de aplicação da visão computacional em cirurgia cardiovascular, está na compreensão dos comportamentos individuais e da equipe. Outros campos da medicina e da psicologia já estão usando a posição do corpo automatizada e rastreamento de movimento para investigar comportamentos humanos não-verbais.<sup>35</sup> Em cirurgia, a maioria das aplicações dessa tecnologia envolve o rastreamento dos gestos do cirurgião e do movimento das mãos



para extrair métricas objetivas de habilidades psicomotoras técnicas.<sup>36</sup> No entanto, estudos recentes exploraram o uso de dados de posição e movimento gerados por aplicativos de visão computacional para medir a dinâmica e a coordenação da equipe na sala de cirurgia. A centralidade da equipe e a proximidade da equipe são exemplos de métricas comportamentais investigadas nesses estudos.<sup>37</sup>

## TENDENCIAS FUTURAS

Pesquisas recentes em cirurgia cardíaca têm como objetivo integrar dados fisiológicos dos cirurgiões com dados do paciente e dos dispositivos médicos da sala de cirurgia,

para avaliação do desempenho cognitivo principalmente nos momentos de crise.<sup>38</sup> Outros estudos buscam otimizar a coordenação cirúrgica e a comunicação da equipe usando uma abordagem baseada em dados que integra fatores humanos e não humanos com o intuito de aumentar a segurança e mitigar erros durante as cirurgias cardíacas.<sup>39,40</sup>

## CONFLITOS DE INTERESSE

Os autores declaram não possuir conflitos de interesse na realização deste trabalho.

## REFERÊNCIAS

1. Tonidandel S, King EB, Cortina JM. *Big Data at Work: The Data Science Revolution and Organizational Psychology*. New York: Routledge; 2015.
2. Sapiro G, Hashemi J, Dawson G. Computer vision and behavioral phenotyping: an autism case study. *Curr Opin Biomed Eng*. 2019;9:14–20.
3. Chen J, Cheng N, Cacciamani G, Oh P, Lin-Brandt M, Remulla D, et al. Objective Assessment of Robotic Surgical Technical Skill: A Systematic Review. *J Urol*. 2019;201:461–9.
4. Benedetto U, Dimagli A, Sinha S, Cocomello L, Gibbison B, Caputo M, et al. Machine learning improves mortality risk prediction after cardiac surgery: Systematic review and meta-analysis. *J Thorac Cardiovasc Surg*. 2020;S0022-5223(20): 32357-6.
5. Mejia OA, Lisboa LA, Puig LB, Moreira LF, Dallan LA, Pomerantzeff PM, et al. InsCor: a simple and accurate method for risk assessment in heart surgery. *Arq Bras Cardiol*. 2013;100(3):246-54.
6. Mejia OAV, Antunes MJ, Goncharov M, Dallan LRP, Veronese E, Lapenna GA, et al. Predictive performance of six mortality risk scores and the development of a novel model in a prospective cohort of patients undergoing valve surgery secondary to rheumatic fever. *PLoS One*. 2018;13(7):e0199277–e0199291.
7. Chang Junior J, Binuesa F, Canejo LF, Turquetto ALR, Arita ECTC, Barbosa AC, et al. Improving preoperative risk-of-death prediction in surgery congenital heart defects using artificial intelligence model: A pilot study. *PLoS One*. 2020;15(9):e0238199–e0238220
8. Mejia OAV, Borgomoni GB, Zubelli JP, Dallan LRP, Pomerantzeff PMA, Oliveira MAP et al. Validation and quality measurements for STS, EuroSCORE II and a regional risk model in Brazilian patients. *PLoS One*. 2020;15(9):e0238737–e0238753.
9. Collas VM, Van De Heyning CM, Paelinck BP, Rodrigues IE, Vrints CJ, Bosmans JM. Validation of transcatheter aortic valve implantation risk scores in relation to early and mid-term survival: a single-centre study. *Interact Cardiovasc Thorac Surg*. 2016;22(3):273-9.
10. Kilic A. Artificial Intelligence and Machine Learning in Cardiovascular Health Care. *Ann Thorac Surg*. 2020;109(5):1323-1329.
11. Ginty O, Moore JT, Eskandari M, Carnahan P, Monaghan M, Peters TM. Dynamic, Patient-Specific Mitral Valve Modelling for Planning Transcatheter Repairs. *Int J Comput Assist Radiol Surg*. 2019;14(7):1127-35.
12. Saeidi H, Opfermann JD, Kam M, Wei S, Leonard S, Hsieh MH, et al. Autonomous robotic laparoscopic surgery for intestinal anastomosis. *Sci Robot*. 2022;7(62):eabj2908.
13. Feizi N, Tavakoli M, Patel RV, Atashzar SF. Robotics and AI for Teleoperation, Tele-Assessment, and Tele-Training for Surgery in the Era of COVID-19: Existing Challenges, and Future Vision. *Front Robot AI*. 2021;8:610677.
14. Kassahun Y, Yu B, Tibebe AT, Stoyanov D, Giannarou S, Metzner JH, et al. Surgical robotics beyond enhanced dexterity instrumentation: a survey of machine learning techniques and their role in intelligent and autonomous surgical actions. *Int J Cars*. 2016;11:553–68.
15. Maier-Hein L, Vedula SS, Speidel S, Navab N, Kikinis R, Park A, et al. Surgical data science for next-generation interventions. *Nat Biomed Eng*. 2017;1:691–6.
16. Loftus TJ, Tighe PJ, Filiberto AC, Efron PA, Brakenridge SC, Mohr AM, et al. Artificial Intelligence and Surgical Decision-making. *JAMA Surg*. 2020;155(2):148-58.
17. Goldenberg MG, Jung J, Grantcharov TP. Using Data to Enhance Performance and Improve Quality and Safety in Surgery. *JAMA Surg*. 2017;152:972–3.
18. Jung JJ, Jüni P, Lebovic G, Grantcharov T. First-year Analysis of the Operating Room Black Box Study. *Ann Surg*. 2020;271:122–7.
19. Fecso AB, Kuzulugil SS, Babaoglu C, Bener AB, Grantcharov TP. Relationship between intraoperative non-technical performance and technical events in bariatric surgery. *Br J Surg*. 2018;105:1044–50.
20. Lee HC, Yoon HK, Nam K, Cho YJ, Kim TK, Kim WH. et al. Derivation and Validation of Machine Learning Approaches to Predict Acute Kidney Injury after Cardiac Surgery. *J Clin Med*. 2018;7:322-33.
21. Likosky D, Yule SJ, Mathis MR, Dias RD, Corso JJ, Zhang M, et al. Novel Assessments of Technical and Nontechnical Cardiac Surgery Quality: Protocol for a Mixed Methods Study. *JMIR Res Protoc*. 2021;10(1):e22536- e22547.
22. Wahr JA, Prager RL, Abernathy JH 3rd, Martinez EA, Salas E, Seifert PC, et al.; American Heart Association Council on Cardiovascular Surgery and Anesthesia, Council on Cardiovascular and Stroke Nursing, and Council on Quality of Care and Outcomes Research. Patient safety in the cardiac operating room: human factors and teamwork: a scientific statement from the American Heart Association. *Circulation*. 2013;128:1139–69.
23. Hazlehurst B, McMullen CK, Gorman PN. Distributed cognition in the heart room: how situation awareness arises from coordinated communications during cardiac surgery. *J Biomed Inform*. 2007;40:539–51.
24. Zenati MA, Kennedy-Metz L, Dias RD. Cognitive Engineering to Improve Patient Safety and Outcomes in Cardiothoracic Surgery. *Semin Thorac Cardiovasc Surg*. 2020;32:1–7.
25. Dias RD, Ngo-Howard MC, Boskovski MT, Zenati MA, Yule SJ. Systematic review of measurement tools to assess surgeons' intraoperative cognitive workload. *Br J Surg*. 2018;105:491– 501.
26. Sharma D. Toward a new foundation of human-computer interaction. *Proceedings of the 3rd International Conference on Electronics Computer Technology*; 2011 Apr 8-10; Kanyakumari, India. Winston-Salem, NC: Institute of Electrical and Electronics Engineers Inc; 2013.
27. Kenngott HG, Apitz M, Wagner M, Preukschas AA, Speidel S, Müller-Stich BP. Paradigm shift: cognitive surgery. *Innov Surg Sci*. 2017;2:139–43.
28. Szeliski R. *Computer Vision: Algorithms and Applications*. London: Springer-Verlag; 2011.

29. Spinrad N. Google car takes the test. *Nature*. 2014;514:528.
30. Gomes JF, Leta FR. Applications of computer vision techniques in the agriculture and food industry: a review. *Eur Food Res Technol*. 2012;235:989–1000.
31. Forestier G, Lalys F, Riffaud L, Trelhu B, Jannin P. Classification of surgical processes using dynamic time warping. *J Biomed Inform*. 2012;45:255–64.
32. Padoy N. Machine and deep learning for workflow recognition during surgery. *Minim Invasive Ther Allied Technol*. 2019;28:82–90.
33. Bouget D, Allan M, Stoyanov D, Jannin P. Vision-based and markerless surgical tool detection, and tracking: a review of the literature. *Med Image Anal*. 2017;35:633–54.
34. Jannin P, Fitzpatrick JM, Hawkes DJ, Pennec X, Shahidi R, Vannier MW. Validation of medical image processing in image-guided therapy. *IEEE Trans Med Imaging*. 2002;21:1445–9.
35. Sapiro G, Hashemi J, Dawson G. Computer vision and behavioral phenotyping: an autism case study. *Curr Opin Biomed Eng*. 2019;9:14–20.
36. Chen J, Cheng N, Cacciamani G, Oh P, Lin-Brandt M, Remulla D, et al. Objective Assessment of Robotic Surgical Technical Skill: A Systematic Review. *J Urol*. 2019;201:461–9.
37. Dias RD, Yule SJ, Kennedy-Metz L, Zenati MA. Psycho-physiological Data and Computer Vision to Assess Cognitive Load and Team Dynamics in Cardiac Surgery. *Semin Thorac Cardiovasc Surg*. 2019;32-36.
38. Dias RD, Conboy HM, Gabany JM, Clarke LA, Osterweil LJ, Arney D, et al. Intelligent Interruption Management System to Enhance Safety and Performance in Complex Surgical and Robotic Procedures. *OR 2.0 Context Aware Oper Theaters Comput Assist Robot Endosc Clin Image Based Proced Skin Image Anal* (2018). 2018;11041:62–8.
39. Arney D, Rance G, Rithy S, Goldman JM, Zenati MA. A Novel Interoperable Safety System for Improved Coordination and Communication in Cardiac Surgery. *OR 2.0 Context Aware Oper Theaters Comput Assist Robot Endosc Clin Image Based Proced Skin Image Anal* (2018). 2018;11041:39–45.
40. Rance G, Arney D, Srey R, Goldman JM, Zenati MA. Establishing a Ventilator-Heart Lung Machine Communication Bridge to Mitigate Errors when Weaning from Bypass. *J Extra Corpor Technol*. 2019;51:38–40.

# INTELIGÊNCIA ARTIFICIAL NA TOMADA DE DECISÃO CLÍNICA EM MEDICINA CARDIOVASCULAR

## ARTIFICIAL INTELLIGENCE IN CLINICAL DECISION MAKING IN CARDIOVASCULAR MEDICINE

Pedro Gabriel Melo de Barros e Silva<sup>1-5</sup>  
Tiago Frigini<sup>5</sup>  
Renato Delascio Lopes<sup>1,2</sup>  
Bernardo Baptista da Cunha Lopes<sup>5</sup>  
Ariane V. Scarlatelli Macedo<sup>1,2</sup>  
Bruno R. Nascimento<sup>6</sup>  
Valter Furlan<sup>5</sup>  
Antonio Luiz P. Ribeiro<sup>6</sup>

1. Hospital Samaritano Paulista. São Paulo, SP, Brasil.
2. Brazilian Clinical Research Institute. São Paulo, SP, Brasil.
3. HCOR Research Institute. São Paulo, SP, Brasil.
4. Centro Universitario São Camilo. São Paulo, SP, Brasil.
5. United Health Group Brazil. São Paulo, SP, Brasil.
6. Faculdade de Medicina da Universidade Federal de Minas Gerais. MG, Brasil.

Correspondência:  
Pedro Gabriel Melo de Barros e Silva  
pedro.barros@bcri.org.br

### RESUMO

Assim como nas atividades cotidianas, a prática médica contemporânea gera uma enorme quantidade de dados que frequentemente não se traduzem em informações clinicamente úteis, uma vez que a capacidade intelectual humana apresenta limitações para lidar com o chamado *big data*. A inteligência artificial (IA) possibilita a elaboração e a aplicação de algoritmos capazes de simular a inteligência humana, entretanto, processando um enorme volume de dados em curto intervalo de tempo. As informações geradas pela IA permitem aperfeiçoar modelos de decisão nos diferentes domínios do conhecimento, inclusive a prática médica, em que ferramentas de IA aprimoram a tomada de decisões, particularmente quanto às inferências de probabilidades relacionadas com diagnóstico e prognóstico. Na cardiologia, há diversas aplicações da IA, como na priorização e aprimoramento de análise de exames, telemonitoramento, detecção de fibrilação atrial, predição de eventos cardiovasculares a longo e curto prazo (por exemplo, em um protocolo de dor torácica), avaliação de doenças cardíacas estruturais, dentre outras. Embora a IA tenha um enorme potencial disruptivo, há aspectos desafiadores de implicações relacionadas com o avanço da IA na cardiologia. Há necessidade de vigilância contínua sobre o funcionamento dessas ferramentas, incluindo o respeito aos preceitos éticos vigentes. A formação do médico também deverá ser adaptada para que o futuro médico possa aplicar corretamente não apenas o conhecimento clínico prático individual, mas também a correta interpretação e aplicação de dados (relação médico-paciente-dados). O presente artigo aborda as principais definições de IA, suas aplicações na tomada de decisão cardiovascular e os limites atuais dessas ferramentas.

**Descritores:** Aprendizado de Máquina; Medicina; Cardiologia.

### ABSTRACT

*Just as in daily activities, contemporary medical practice generates a huge amount of data that often is not translated into clinically useful information because human intellectual capacity has limitations when dealing with the so-called "big data". Artificial intelligence (AI) enables the development and application of algorithms capable of simulating human intelligence, however, processing a huge volume of data in a short time. The information generated by AI allows the development of better decision models in different knowledge domains, including in medical practice, where AI tools improve decision making, particularly in inferences of probabilities related to diagnosis and prognosis. In cardiology, there are several applications of AI, such as prioritization and improvement of exam analysis, telemonitoring, detection of atrial fibrillation, prediction of cardiovascular events in the long and short term (e.g., in a chest pain protocol), and assessment of structural heart diseases, among others. While AI has enormous disruptive potential, there are challenging aspects of implications related to the advancement of AI in cardiology. There is a need to have continuous surveillance on the functioning of these tools, including respect for current ethical precepts. The training of physicians should be modified so that they can correctly apply not only individual practical clinical knowledge but also the correct interpretation and application of data (doctor-patient-data relationship). The current article addresses the main definitions of AI, its applications in cardiovascular decision making, and the current limitations of these tools.*

**Keywords:** Machine Learning; Medicine; Cardiology.

## INTRODUÇÃO

Na sociedade contemporânea, as atividades cotidianas geram uma enorme quantidade de dados, os quais crescem de forma exponencial ao longo dos anos, entretanto, são subaproveitados em termos de informações. Isso ocorre, pois, a capacidade intelectual humana tem limitações para lidar com um alto volume de dados, tendo que selecionar quais informações irá assimilar, de acordo com a conveniência e a necessidade. A Inteligência artificial (IA) representa a expressão da inteligência humana executada exteriormente (“fora” do nosso cérebro) como um resultado da combinação de modelos matemáticos e da computação, para produzir algoritmos refinados capazes de “imitar” a inteligência humana, ou seja, sistemas que pensam e agem de forma similar ao modelo racional dos seres humanos.<sup>1-6</sup> De uma forma evolutiva, a inteligência artificial representa a terceira era da computação, sucedendo a era da produtividade (década de 80) e a era da internet (década de 90). Nesta fase atual, os computadores deixam de ser considerados apenas produtos e passam a ser integrados como parte da experiência de vida de seus usuários, sendo ferramentas fundamentais não apenas na construção e compartilhamento de conhecimento, mas também na formulação e ajuste de modelos de decisão nos diferentes domínios do conhecimento. Dentro desse contexto em que a IA faz parte da experiência de vida das pessoas, há aplicações desse recurso em nas diversas áreas do conhecimento humano, incluindo a medicina.

Nesta incorporação da IA na rotina da sociedade, há impacto desta tecnologia na atuação de diferentes profissionais com enorme potencial para melhorar o desempenho nas rotinas de trabalho. O termo IA foi utilizado pela primeira vez na década de 50, enquanto pesquisas formais sobre aplicações da IA na área médica começaram na década de 70 e foram divulgadas desde então de forma progressiva, particularmente com a construção de programas de IA que realizam diagnósticos e fazem recomendações terapêuticas.<sup>1-6</sup> Tendo em vista a enorme quantidade de dados coletados (*Big Data*), os avanços ao nível de hardware (processamento paralelo) e a evolução de diversos ramos da inteligência artificial (ex: diferentes métodos de aprendizado de máquina), a IA representou um caminho real de aplicação prática para o aprimoramento da tomada de decisões na medicina, particularmente em diagnóstico e prognóstico. As atividades relacionadas à saúde já contam com diversos serviços de IA no auxílio diagnóstico e terapêutico inseridos na prática médica habitual. Além disso, ações inovadoras para monitoramento de pacientes ambulatoriais, que até então não eram parte da rotina assistencial, vem sendo incorporadas de forma progressiva. Apesar da evolução animadora em relação ao potencial de facilitar a decisão médica, há também preocupações quanto ao papel do médico na era da inteligência artificial. Frases como “Em um futuro não muito distante, um programa de computador artificialmente inteligente provavelmente diagnosticará as doenças cardíacas com mais precisão que um cardiologista certificado”<sup>1</sup> geram inicialmente uma expectativa ameaçadora da inteligência artificial para os cardiologistas e outros profissionais da área médica. Essa ameaça não se resume aos médicos apenas, mas também está presente em diversos outros segmentos profissionais da sociedade. No sentido de entendermos

melhor o que representa a IA e suas principais aplicações na cardiologia, faz-se mister definir o que significa IA, assim como seus “ramos” (como machine learning e deep learning), suas aplicações atualmente propostas com seu potencial de melhora de processos e rotinas, e os principais conceitos que compõem esta nova era da computação.

## SISTEMAS ESPECIALISTAS

Os chamados de “sistemas especialistas” ainda representam a maior parte das técnicas convencionais usadas em sistemas computacionais (inclusive na medicina). Não são considerados como IA de fato e empregam simplesmente o conceito de algoritmos baseados em regras já conhecidas. Por outro lado, as técnicas de inteligência artificial manuseiam um grande número de variáveis (inclusive em escalas consideradas como *big data*) em busca de novas combinações que possam prever um resultado com confiabilidade.<sup>2</sup>

## BIG DATA

No início do século XXI, Doug Laney definiu um modelo de “3 Vs” para conceituar o termo *big data*: volume, velocidade e variedade, todos os “Vs” em larga escala. Este enorme volume de dados exige novas técnicas de processamento de forma a permitir descobertas e otimizar processos para gerar informações úteis. Outra forma de conceituar o termo *big data* seria: 1) um conjunto de dados de tamanho enorme, que nenhuma das ferramentas tradicionais de gerenciamento de dados é capaz de realizar análise, pesquisa, interpretação e armazenamento com eficiência; 2) tipo de tecnologia (como instalações de armazenamento, ferramentas e processos de grandes dados); 3) dados que se destacam não apenas pelo volume, mas também pela velocidade de crescimento, com alguns autores propondo, com base em buscas na literatura, que o termo pode ser aplicado a conjuntos de dados com  $\text{Log}(n * p) \geq 7$ , em que  $n$  é o número de indivíduos, e  $p$  o número de variáveis no modelo estatístico.<sup>3</sup>

Como definido no conceito dos 3 “Vs”, a uma grande variedade de dados que podem ser utilizados, sendo atualmente mais acessíveis os dados socio-demográficos, ambientais, clínicos e laboratoriais. Dados adicionais têm sido progressivamente disponibilizados como os dados fisiológicos de “wearables” (“vestíveis”) assim como dados ômicos (genoma, metaboloma, proteoma) e informações das intensidades de vermelho, verde e azul (sistema RGB) de cada pixel que compõe uma imagem decomposta em seus componentes estruturais básicos, por exemplo.

## INTELIGÊNCIA ARTIFICIAL

A inteligência artificial (IA) representa um grupo de diferentes métodos que proporcionam a combinação de modelos da computação e matemáticos sofisticados, no sentido de produzir algoritmos complexos que possuem a capacidade de emular (imitar) a inteligência humana.<sup>4</sup>

A depender de como essa IA se compara a um humano, seja em versatilidade ou desempenho, ela pode ser classificada entre os diversos tipos de IA. De forma sucinta, geralmente são usados dois tipos de classificação, uma relacionada à capacidade da IA, com quatro subdivisões: máquinas reativas, memória limitada, teoria da mente e autoconsciente; e outra,

mais comum, que divide essa tecnologia em três grupos: Inteligência Artificial Estreita (ou ANI, do inglês Artificial Narrow Intelligence), Inteligência Artificial Geral (ou AGI, do inglês Artificial General Intelligence) e Superinteligência Artificial (ou ASI, do inglês Artificial Superintelligence).

Máquinas reativas são o tipo mais primitivo de IA e possuem a capacidade de apenas responder automaticamente a um conjunto limitado de entrada. Seu exemplo clássico é o Deep Blue, da IBM, programado para jogar xadrez. Praticamente todos os sistemas de IA da atualidade são classificados como memória limitada, uma vez que, além de possuírem as capacidades das máquinas reativas, também possuem memória, ou seja, são capazes de aprender com dados históricos para tomar decisões. Elas são treinadas usando grandes bases de dados que são armazenados em sua memória para formar um modelo de referência e assim serem capazes de resolver problemas futuros. O próximo nível, no qual está concentrado o trabalho de evolução atualmente, é o de teoria da mente, no qual a IA será capaz entender melhor as entidades com as quais está interagindo, através do reconhecimento de suas necessidades, crenças, emoções e processos / fluxos de pensamento. O estágio "final" do desenvolvimento da IA é o de autoconsciência, que atualmente existe apenas hipoteticamente. Esse é o estágio temido pelos "profetas do apocalipse", uma vez que esse tipo de IA poderá entender e provocar emoções nas pessoas com quem interage, mas também ter emoções, necessidades, crenças e potencialmente desejos próprios. Uma vez autoconsciente, essa IA terá a capacidade de ter ideias como sua autopreservação e isso pode causar, direta ou indiretamente, o fim da humanidade, como exemplificado no filme "Matrix".

Na segunda forma de classificação, temos a Inteligência Artificial Estreita, que representa todos os exemplos de IA existentes até hoje. Independentemente da complexidade da sua programação, não podem fazer nada além do que foram programadas para fazer e, portanto, possuem uma gama limitada

de capacidades. Os sistemas classificados como máquinas reativas e memória limitada estão incluídos nessa categoria. A IA Geral representa a habilidade da IA aprender, perceber, entender e funcionar como um ser humano. Esses sistemas serão capazes de criar múltiplas competências, formar conexões e generalizações entre domínios, reduzindo massivamente o esforço e tempo de treinamento necessário. Nesse estágio, a IA será tão capaz quanto um ser humano, ao replicar nossas capacidades multifuncionais. A Superinteligência Artificial marcará o ápice do desenvolvimento dessa tecnologia, uma vez que a forma de inteligência mais capaz da terra será artificial. A ASI será extremamente melhor em tudo que faz, por conta de capacidades assustadoramente maiores de memória, processamento, análise e tomada de decisões. Esse ponto do desenvolvimento é conhecido como singularidade, uma vez que um algoritmo será capaz de programar um outro algoritmo melhor do que o melhor programador humano e representa a ameaça mencionada anteriormente no subtipo autoconsciente da classificação anterior.

No cenário atual, estes algoritmos não são inteligentes "per se", mas atuam no auxílio de pessoas no sentido de explorar e analisar conjuntos de dados amplos e complexos para que seja possível encontrar sentido neles. Em outras palavras, a IA serve como um apoio para situações em que há limitações da capacidade intelectual humana para lidar com um alto volume de dados e informações, e para compilar e/ou analisar estes conjuntos de dados de forma acurada e reprodutível. (Figura 1) Desse modo, a IA é um conceito amplo que engloba a execução de tarefas que normalmente estão relacionadas à inteligência humana, tais como reconhecimento de padrões, resolução de problemas, compreensão de linguagem ou reconhecimento de objetos e sons.<sup>4,5</sup>

A partir do seu surgimento, os sistemas que faziam apenas aquilo que eram programados para fazer evoluíram para sistemas capazes de organizar e analisar um altíssimo volume de dados, de interagir com os humanos de maneira mais natural e de trazer hipóteses de soluções para

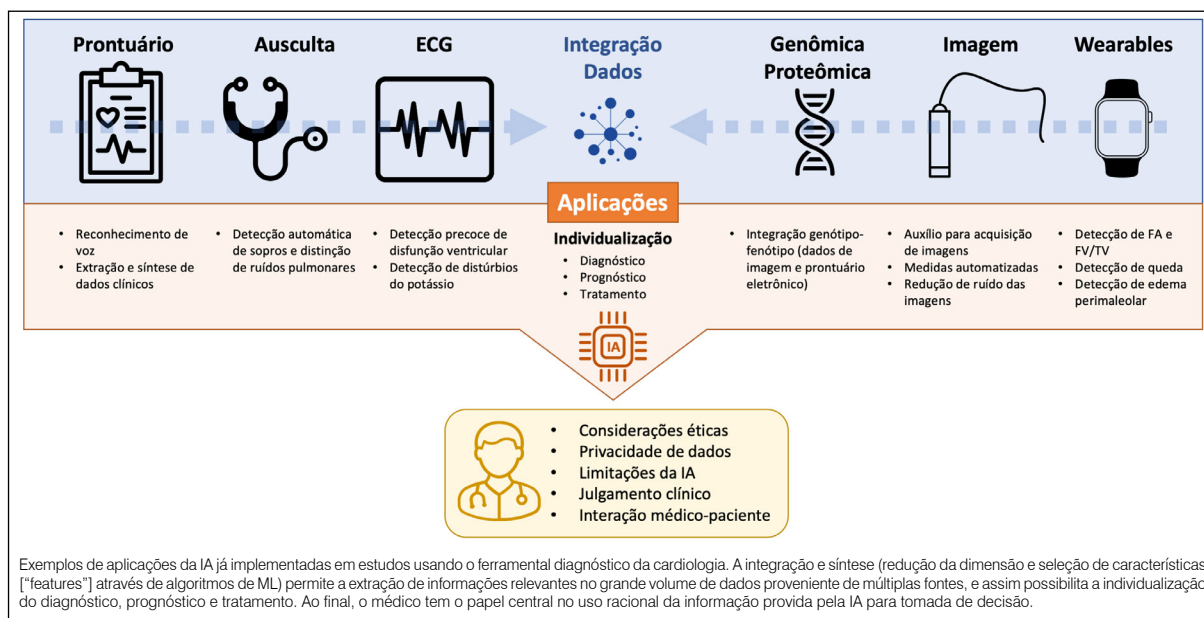


Figura 1. Inteligência Artificial no Auxílio à Tomada de Decisão Clínica em Medicina Cardiovascular.

inúmeros problemas. Importante ter em mente de que todo esse processo se inicia com a construção de um banco de dados representativo do problema que se deseja estudar. Estes dados devem ser “saudáveis”, ou seja, coletados e processados de forma adequada. É fundamental obter dados saudáveis uma vez que os algoritmos, via de regra, não terão um bom desempenho sem este pré-requisito (dependem dele). Após ter acesso a um banco composto por dados saudáveis, deve-se analisar quais os modelos mais apropriados de IA para o tipo problema a ser resolvido (uma vez escolhidos, estes modelos devem ser implementados utilizando uma linguagem de programação). Desse modo, a evolução da IA gerou a existência de diversos ramos, como a mineração de dados, aprendizado de máquina, deep learning. Desse modo, o aprendizado de máquina é um subconjunto de algoritmos de IA relacionados à capacidade de aprender a partir de uma grande quantidade de dados.<sup>4</sup>

## APRENDIZADO DE MÁQUINA (MACHINE LEARNING)

O Aprendizado de Máquina ou Machine Learning (ML) é uma subárea da ciência da computação, “ramo” da Inteligência Artificial, e que representa a ferramenta de maior aplicação atualmente. Diferente de instruções préprogramadas que vinham sendo utilizadas nas eras iniciais da computação, o ML busca uma interseção de técnicas matemáticas e estatísticas com algoritmos computacionais para o estudo e a construção de algoritmos computacionais a partir do aprendizado por dados.<sup>2,6,7</sup> Dessa forma, trata-se de um ramo da IA cujo objetivo primordial seria o de construir um sistema computacional que utiliza algoritmos para aprender com um banco de dados pré-definido, sendo aplicada em situações em que se buscam padrões em um conjunto de variáveis, com o intuito de prever um resultado específico de interesse (encontrar relação de dados para fazer classificações, prever valores, ou seja, possa gerar modelos matemáticos de predição, classificação ou detecção).<sup>7,8</sup>

Na prática, a aplicação de ML está relacionada principalmente no manuseio de bases de dados consolidadas com informações heterogêneas, para as quais há uma limitação do uso das técnicas de estatística convencionais.<sup>9</sup>

O processo de desenvolvimento de um algoritmo de ML é dividido em três fases:

**Pré-processamento:** consiste em organizar o banco de dados, definir a pergunta de pesquisa e dividir os dados em treinamento e teste.

**Treinamento:** nesta fase o aprendizado pode ocorrer de forma supervisionada ou não supervisionada.<sup>10,11</sup>

**Avaliação do modelo:** ao final, o modelo é comparado com os dados de teste e os resultados são gerados. Além desta fase de testes com a base de dados original segmentada (em dados de treinamento e validação), o modelo pode também ser validado externamente, com outras bases de dados, oriundas de outras populações, contextos ou cenários. A validação externa acrescenta robustez ao modelo, favorecendo sua aplicabilidade prática.

Existem alguns tipos de aprendizado de máquina que podem ser classificados em relação a “supervisão”: supervisionado, não supervisionado, semi-supervisionado e auto-supervisionado; mas também existem outros tipos que não se

encaixam nessa classificação: Inferência Causal e Reforço.

**a. Supervisionados:** os modelos chamados de supervisionados são baseados no treinamento de uma amostra de dados com a classificação correta já atribuída. Dessa forma, o algoritmo recebe informações sobre cada lição, bem como os rótulos associados a ela (o modelo do ML tem o conhecimento do rótulo dos dados, ou seja, as amostras estão corretamente classificadas). Este modelo tem um papel importante em relação à previsão de eventos (o treinamento é baseado na comparação entre o resultado obtido do modelo e o rótulo previamente classificado; esse processo é repetido até se obter um erro mínimo).<sup>10</sup> Entretanto, como realizar essa classificação prévia pode ser custoso em tempo e dinheiro, esses datasets são difíceis de obter e, portanto, frequentemente são reutilizados em múltiplos estudos.<sup>11</sup>

**b. Não-supervisionado:** esta classificação se refere à capacidade de aprender e organizar informações sem a atribuição da classificação correta. Desse modo, os rótulos das lições não são fornecidos *a priori* e cabe ao algoritmo encontrar estruturas ocultas no banco de dados (este modelo do ML não tem o conhecimento do rótulo dos dados inicialmente). Este modelo extrai as características dos dados e constrói uma representação sem o conhecimento prévio dos rótulos de cada dado, ou seja, identifica o padrão das informações de classe heurísticamente (essa falta de supervisão para o algoritmo pode ser vantajosa, pois permite que o algoritmo não fique limitado aos rótulos conhecidos e analise os padrões que não foram considerados anteriormente).<sup>7,10,11</sup>

**c. Semi-supervisionado:** setup no qual o algoritmo é treinado a partir de poucos exemplos rotulados e um segundo conjunto de dados não rotulados (uma das metas é o treinamento de classificadores quando uma grande quantidade de dados não rotulados está disponível juntamente com um pequeno conjunto de dados rotulados).

**d. Auto-supervisionado:** trata-se de uma linha recente de pesquisa, na qual utiliza-se de estruturas criadas para o aprendizado supervisionado ou semi-supervisionado, realizando o treinamento com rótulos obtidos por técnicas não supervisionadas ou pela comparação entre elementos do conjunto, sem utilização de nenhuma informação prévia sobre os mesmos. É comumente referenciado como método semelhante ao qual seres humanos aprendem a classificar objetos.

**e. Reforço:** modelo de aprendizado baseado em recompensa<sup>12,13</sup> inspirado na biologia comportamental, no qual o algoritmo não recebe a resposta correta, mas um sinal de reforço, positivo ou negativo, baseado na hipótese formulada. Esse modelo é bastante utilizado em jogos e robótica.

**f. Inferência causal:** método no qual procura-se isolar o efeito de um componente ou tratamento em um sistema, usando o conjunto de dados. Máquinas tipicamente têm dificuldade de identificar causalidade, uma vez que esse conceito não pode ser explicado completamente em uma lógica booleana. Ao ver um jogador de beisebol rebatendo uma bola, nós sabemos intuitivamente que o braço do jogador é o responsável por mover o taco, mas uma máquina pode inferir que foi o taco que moveu o braço do jogador.

Em resumo, os algoritmos de ML aprendem através de repetidas observações e então estabelecem um padrão de mapeamento com o objetivo de rotular os dados e criar um

modelo que generaliza as informações, de modo que novos dados (nunca antes analisados pelo algoritmo) possam ser rotulados com precisão e confiabilidade.<sup>10</sup> Vale ressaltar que, se a base de dados não for saudável (dados não consolidados), os modelos de ML podem gerar resultados enganosos (fundamental que a base de dados seja consolidada e validada para o que o processo de desenvolvimento de um algoritmo de ML seja adequado).

## Deep Learning

*Deep learning*, uma das modalidades de ML, difere o seu aprendizado das técnicas mais tradicionais de ML, pois processa modelos computacionais mais robustos e com múltiplas camadas de processamento baseadas em redes neurais artificiais. Assim é semelhante a uma rede neural artificial, mas possuindo um número maior de camadas ocultas e, por consequência, mais conexões sinápticas. Cada camada reproduz uma representação dos dados oriundos da camada anterior e seu algoritmo de aprendizado pode ser tanto supervisionado como não supervisionado.<sup>1-5,7,10,11</sup>

## Computação Cognitiva

Pode ser entendida como um conjunto de sistemas de autoaprendizagem destinados a imitar o processo de pensamento humano com base no uso de ferramentas de ML, reconhecimento de padrões e processamento natural de linguagem (por exemplo, o IBM Watson).<sup>3,14</sup>

## Necessidades que podem ser atendidas pela Inteligência Artificial na Cardiologia

Os algoritmos de ML já estão presentes em diferentes segmentos da sociedade (ex: sites de busca na internet, detecção de fraudes em sistemas bancários) incluindo a medicina (especialmente para fins diagnósticos e prognósticos).<sup>1-5</sup> Vivemos na era dos dados, e da mesma forma que houve um aumento exponencial na geração de dados nas atividades cotidianas da sociedade atual, houve também na medicina, especialmente com a digitalização dos documentos médicos que incluem prontuários, exames laboratoriais e de imagem e, mais recentemente, com a disponibilidade de dados genéticos e de telemonitoramento através dos chamados *wearables*.<sup>7,15</sup> Esse grande volume e complexidade de dados, ou *big data*, é propício para a aplicação de técnicas de IA (particularmente ML) que não exigem muitas suposições em relação aos dados subjacentes mas que podem gerar informações novas com potencial impacto na prevenção, diagnóstico e tratamento precoce (e assertivo) de diversas doenças.<sup>7,15</sup>

O ambiente de *big data* é favorável para aplicação de técnicas de IA já que a mente humana não consegue processar e armazenar todo o crescimento do conhecimento biomédico assim como não tem a capacidade de assimilar e gerenciar a crescente quantidade de dados e informações sobre os pacientes. Nesse contexto, a Inteligência Artificial (IA) tem um papel relevante no apoio à tomada de decisões em saúde, ao menos como ferramenta de filtragem e seleção de dados, o que já é um avanço importante no gerenciamento da saúde. Desse modo, a IA apresenta enorme potencial para participar de forma relevante na tomada de decisão dos cardiologistas pois possibilita a aplicação de novas informações de forma

abrangente e em tempo hábil.<sup>1</sup> Finalmente, a tecnologia pode simplificar e acelerar os processos diagnósticos e, por consequência, influenciar positivamente na redução da sobrecarga médica, o que pode reduzir a vulnerabilidade para erros médicos e minimizar o impacto do *burnout* entre profissionais de saúde.<sup>4</sup>

Além do potencial benefício teórico da IA na medicina, há demonstração prática da sua performance como em um exemplo emblemático em que uma rede neural artificial apresentou capacidade semelhante a de um comitê de 21 dermatologistas na avaliação de mais de 100.000 casos para diferenciação entre lesões dermatológicas benignas *versus* malignas.<sup>16</sup> Outro estudo clássico demonstrou a capacidade de uma rede neural para o correto diagnóstico de alterações genéticas em glioblastomas a partir de imagens de ressonância magnética, em comparação com biomarcadores e avaliação por especialistas.<sup>17</sup> Isso demonstrou a capacidade de desenvolvimento de excelentes modelos preditivos e, além da capacidade de criar modelos novos, a IA possibilita também a otimização de modelos existentes.

## APLICAÇÃO ATUAL DA INTELIGÊNCIA ARTIFICIAL NA CARDIOLOGIA

A Cardiologia está na vanguarda do desenvolvimento de aplicações de IA na medicina. O avanço na capacidade computacional e nas técnicas de ML e redes neurais têm propiciado o desenvolvimento de ferramentas valiosas para o cardiologista. (Figura 2)

A melhora dos algoritmos de diagnóstico eletrocardiográfico, a automatização de medidas em imagens cardíacas, o avanço dos wearables na detecção precoce de fibrilação atrial, a otimização de modelos de predição risco cardiovascular, dentre outros, são exemplos onde as técnicas ML estão alavancando o instrumental para diagnosticar e prever eventos em doenças cardíacas.<sup>3</sup>

Priorização e aprimoramento de análise de exames:<sup>18,19</sup>

A extração e a síntese de características (ou *features*) de maior relevância clínica em um conjunto de dados grande e heterogêneo, seja ele de eletrocardiograma, imagens cardíacas, ou prontuário eletrônico (texto livre), é uma das aplicações mais exploradas atualmente dos algoritmos de ML.

Uma das primeiras aplicações da IA na prática médica foi na detecção de achados de maior gravidade em exames eletrocardiográficos em uma fila de espera. A depender do tipo de exame e cenário clínico, esta priorização pode ter impacto direto no desfecho do paciente. Por exemplo, em uma fila de eletrocardiogramas de pacientes de emergência, exames com alteração do segmento ST poderiam ser priorizados, gerando assim redução de tempo para o diagnóstico nos casos de síndrome coronária aguda com elevação de ST.

Além de priorizar, os algoritmos de ML e *deep learning* têm melhorado a acurácia do diagnóstico de exames como o eletrocardiograma<sup>18</sup> e o ecocardiograma.<sup>20,21</sup> Desse modo, essas análises mais acuradas baseadas em IA podem servir como uma forma de auditoria de qualidade dos exames avaliados pelo médico. Havendo discordância entre o laudo do médico e da IA, este poderia ser revisto por um grupo de médicos experientes que atuem no controle de qualidade. Por fim, o resultado da avaliação deste comitê poderia gerar feedback para aprimoramento da IA.

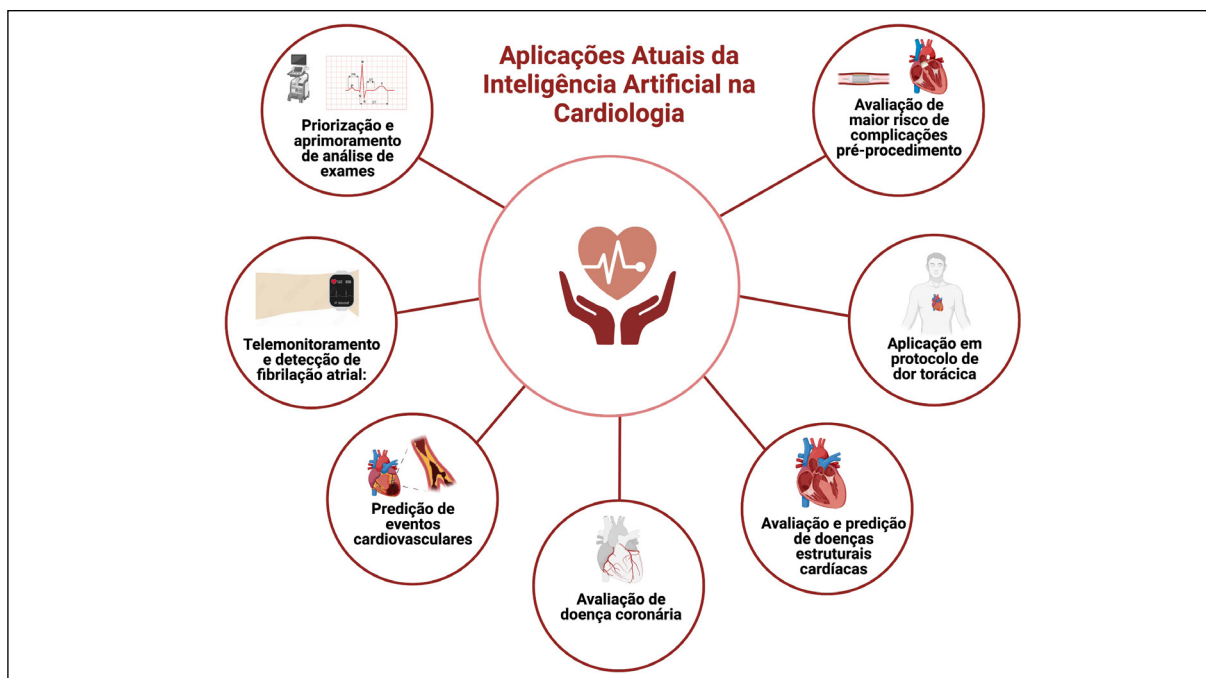


Figura 2. Aplicações atuais da inteligência artificial na cardiologia.

Outro exemplo onde a IA poderia aprimorar a análise diagnóstica seria ao guiar, por meio das imagens adquiridas em tempo real, o posicionamento do transdutor durante um exame de ecocardiograma, especialmente para apoiar profissionais em locais remotos com recursos limitados e que não tenham expertise para execução.<sup>22</sup> Tal possibilidade pode facilitar e aumentar a disponibilidade de programas de rastreamento ecocardiográfico em regiões com recursos limitados, como por exemplo para detecção de condições negligenciadas como a Cardiopatia Reumática.

Diversas soluções estão sendo desenvolvidas com algoritmos de ML para o processamento automatizado de imagens cardíacas, o que alavanca a produtividade e homogeneiza análises. Em 2016, em competição rankeada e aberta promovida pela plataforma Kaggle, a dupla de cientistas de dados vencedora foi capaz de desenvolver uma rede neural convolucional que calculava automaticamente, em segundos, os volumes e a fração de ejeção do ventrículo esquerdo em imagens de ressonância magnética. Neste modelo, a média de erro de foi de 5% para fração de ejeção e de 10 ml para volumes, mostrando sua excelente acurácia e reduzindo para segundos uma análise habitualmente realizada em 10-15 minutos por médico treinado.

Grandes esforços também vêm sendo empregados no desenvolvimento de modelos de ML para extração de informações de prontuários eletrônicos. Técnicas de ML com processamento de linguagem natural são capazes de extrair e sintetizar as informações clínicas mais relevantes dos prontuários atuais, com dados não estruturados em texto livres. Diversas aplicações são possíveis com a informação extraída, como agilizar revisão de prontuários por equipe médica e administrativa, identificar precocemente eventos adversos, criar de filtros para seleção de candidatos para ensaios clínicos, criação de perfis de pacientes dentro de determinada patologia para individualização do tratamento, dentre outras aplicações.

## TELEMONITORAMENTO E DETECÇÃO DE FIBRILAÇÃO ATRIAL

Dispositivos vestíveis (*wearables*) como o Apple Watch podem detectar variações de frequência cardíaca e do eletrocardiograma, o que possibilita o envio de alertas para realizar rápida avaliação médica em caso de anormalidade. O Apple Heart Study avaliou 419.297 voluntários com o relógio multifuncional da apple, sendo a maioria jovens saudáveis, e o valor preditivo positivo do algoritmo para detecção de fibrilação atrial foi de 71%, o que mostra o potencial da tecnologia, apesar de ainda não estar claro o que fazer com pacientes assintomáticos com episódios esporádicos de fibrilação atrial.<sup>23</sup> Estudo para investigar o impacto dessa tecnologia na redução de eventos está em andamento (NCT04276441).

Além da detecção de fibrilação atrial, a análise de ECGs em ritmo sinusal por meio de ferramentas de ML também permite prever a ocorrência de fibrilação atrial com sensibilidade e especificidade próximas a 80%.<sup>24-26</sup> Como exemplo prático, dispositivos portáteis simples e de baixo custo, com sistemas baseados em AI embarcados, já foram utilizados em programas de rastreamento populacional em combinação com o ecocardiograma, com boa acurácia para detecção de fibrilação atrial (84%) e com significativa associação com anormalidades funcionais e estruturais.<sup>27</sup>

Há ainda os dispositivos de uso específico para telemonitoramento como *patches* (adesivos) e meias inteligentes para monitoramento multiparamétrico. Os patches em geral agregam múltiplos sensores (ECG, impedância intratorácica, termômetro, acelerômetro) que permitem a aquisição, por exemplo, de dados basais de pacientes com insuficiência cardíaca, e a partir desses, com a ajuda de algoritmos de ML, permitem identificar precocemente sinais de descompensação, comparáveis à dispositivos invasivos.<sup>28</sup> Meias inteligentes estão também sendo desenvolvidas para detectar edema em pés através de sensores de estiramento e monitorar atividade física com acelerômetro.<sup>29</sup>



Além do monitoramento remoto (domiciliar), há a possibilidade de ampliar o monitoramento também em pacientes internados. Um estudo multicêntrico com mais de 50.000 pacientes mostrou que um sistema de alerta precoce baseado em *deep learning* (redes neurais artificiais) foi capaz de prever a ocorrência de parada cardíaca em um hospital com desempenho superior comparado aos sistemas tradicionais (área sob a curva de 0,82).<sup>30</sup>

Predição de eventos cardiovasculares:

Diversos dados têm sido avaliados na predição de doença cardiovascular, desde dados clássicos (idade, hábitos de vida, comorbidades) até outras descobertas promissoras sobre a aplicação de ML (como no caso da avaliação de aspectos faciais que se associou com o diagnóstico de doença coronária).<sup>31</sup> Os algoritmos muitas vezes utilizam diversas variáveis do paciente para estimativa de risco (associadas ou não a dados de exames, como eletrocardiograma de repouso ou de esforço);<sup>32</sup> entretanto, tais algoritmos podem também analisar apenas uma única fonte de informação como, por exemplo, apenas o eletrocardiograma.<sup>33</sup> Tal riqueza de informação de um ECG de 12 derivações não é aparentemente detectável pela avaliação médica convencional tendo em vista que uma análise cega destes ECGs realizada por três cardiologistas não detectou este padrão.<sup>33</sup>

De forma semelhante, a utilização de técnicas de *deep learning* aplicadas ao sinal do ECG tem permitido o cálculo da idade cardíaca do paciente.<sup>34,35</sup> A diferença entre a idade obtida pela IA e a idade cronológica tem sido demonstrado como um marcador de risco cardiovascular e pacientes com esta diferença acima de sete ou oito anos, ou seja, idade derivada do ECG acima da idade cronológica em pelo menos sete ou oito anos, tem o risco aumentado de morte<sup>35</sup> e outros eventos cardiovasculares.

Em suas diferentes fontes de informação e métodos de IA, têm se demonstrado que a performance destes modelos de IA têm sido superiores aos modelos tradicionais, como o *Atherosclerosis Cardiovascular Disease Risk Score (ASCVD)*.<sup>36,37</sup> Além do benefício oriundo de fontes de informação já existentes, a IA pode proporcionar o desenvolvimento de modelos preditivos que, embora mais complexos, serão mais personalizados e precisos para cada indivíduo. Isto será possível com a incorporação dos componentes genômicos, proteômicos e metabômicos aos escores de risco cardiovascular. A utilização de ferramentas de IA para análise de um conjunto de dados fenotípicos e “ômicos” irá permitir um grande avanço na medicina de precisão.

## AVALIAÇÃO DE DOENÇA CORONÁRIA

O algoritmo de ML foi capaz de detectar lesões coronarianas superiores ou iguais a 25% com uma sensibilidade 93%, especificidade 95% e acurácia de 94% em 42 angiografias coronárias.<sup>38</sup> Em situações de dúvidas práticas comuns, como no caso de estenoses coronarianas intermediárias pela angiografia, métodos de IA têm sido desenvolvidos para identificar quais teriam reserva de fluxo fracionada menor ou maior que 0,80 com acurácia de aproximadamente 80%.<sup>39</sup>

Além da detecção de graus de lesões coronárias, ferramentas de ML (utilizando dados epidemiológicos clínicos e informações quantitativas e qualitativas da angiotomografia de coronárias) conseguem identificar pacientes com risco de

rápida progressão de placa coronariana com performance melhor que escores tradicionais de risco de doença cardiovascular aterosclerótica em 10 anos.

Em adição ao aperfeiçoamento da avaliação por tomografia, outros métodos não invasivos poderão ter avanço na sua capacidade prognóstica com a junção de dados por ferramentas de IA (como no caso da cintilografia miocárdica que avaliaram a presença de doença coronariana com alta precisão e desempenho superior aos escores tradicionais utilizados).<sup>40</sup> Assim como nos métodos não invasivos, a IA possibilita melhorar o desempenho e facilitar a aplicação de ferramentas invasivas que muitas vezes são subutilizadas na prática clínica. Um exemplo seria em relação ao uso da reserva de fluxo fracionada (FFR) cuja análise da lesão por IA automatizada (AutocathFFR) funcionou em todas as lesões com FFR 0,8 ou inferior e obteve um nível de precisão de 90% para um FFR medido por fio de pressão >0,8.<sup>41</sup>

## APLICAÇÃO EM PROTOCOLO DE DOR TORÁCICA

Na prática médica das últimas décadas, já foi incorporado o uso de escores de probabilidade e risco na avaliação de dor torácica. Entretanto, a grande variedade de escores existentes reforça a limitação deste tipo de ferramenta. A introdução de modelos de IA poderá ser o *pathway* comum na investigação destes pacientes caso demonstre elevada performance e viabilidade prática. Uma ferramenta de ML que utilizou dados da rotina assistencial (sexo, idade e troponina cardíaca) de uma amostra com cerca de 11.000 pacientes, mostrou sucesso na previsão da probabilidade de infarto agudo do miocárdio do tipo 1 (aterotrombótico) com uma AUC de 0,96 (superior às rotas tradicionais).<sup>42</sup> Outro modelo que utilizou dados clínicos, laboratoriais (níveis de troponina I e CK-MB), do ECG e ecocardiográficos de 228 pacientes mostrou sensibilidade acima de 98%, especificidade de 100% e precisão acima de 99%.<sup>43</sup>

Além da probabilidade de IAM, os modelos também podem ser utilizados para prever a mortalidade na síndrome coronariana aguda, com desempenho melhor do que os modelos tradicionais como o escore de GRACE.

A IA também apresenta potencial para aprimorar a análise do ECG como demonstrado em modelos de ML que conseguiram categorizar classes eletrocardiográficas por meio da análise do ECG de 12 derivações com acurácia semelhante à de residentes de cardiologia do último ano.<sup>18,19</sup>

## AVALIAÇÃO E PREDIÇÃO DE DOENÇAS ESTRUTURAIS CARDÍACAS

Na avaliação de dados clínicos, laboratoriais e ecocardiográficos de mais de 1.000 pacientes hipertensos por técnicas de ML, pôde-se identificar pacientes com maior risco de desenvolver insuficiência cardíaca de fração preservada (ICFEP).<sup>44</sup> Na própria ICFEP, um algoritmo de ML que utilizou dados clínicos e eletrocardiográficos conseguiu classificar os pacientes em seis grupos que apresentavam níveis diferentes de marcadores inflamatórios e cardiovasculares e também apresentavam diferentes desfechos.

Técnicas de IA que analisaram banco de dados com mais de 14.000 ecocardiogramas conseguiram detectar com

elevada acurácia (estatística C de 0,85 a 0,93) os diagnósticos de cardiomiopatia hipertrófica, amiloidose cardíaca e hipertensão arterial pulmonar.<sup>45</sup> De forma semelhante, técnicas de ML conseguiram diferenciar pericardite constrictiva de cardiomiopatia restritiva com uma acurácia superior a 90%<sup>46</sup> e conseguiram identificar parâmetros úteis na diferenciação ecocardiográfica entre cardiomiopatia hipertrófica e hipertrofia fisiológica de atletas (razão da velocidade transmitral diastólica precoce-tardia, velocidade diastólica precoce (e') e a análise de *strain*).<sup>47</sup> Ademais, dados oriundos de programas de rastreamento populacionais no Brasil e na África, com mais de 11.600 ecocardiogramas simplificados de rastreamento, têm resultado no contínuo desenvolvimento de redes neurais para detecção automática de Cardiopatia Reumática subclínica, com acurácia superior a 72% até então. O aprimoramento destas redes pode ser uma ferramenta adicional para a transferência de tarefas em ambientes com recursos limitados, facilitando a identificação de indivíduos de alto risco e direcionando o seguimento clínico.<sup>48</sup>

## AVALIAÇÃO DE MAIOR RISCO DE COMPLICAÇÕES PRÉ-PROCEDIMENTO

A aplicação de algoritmos de IA possibilitam identificar com boa acurácia quem são os pacientes de maior risco de complicações hemorrágicas após intervenção coronária percutânea os quais poderiam se beneficiar de estratégias objetivando a redução do risco de sangramento.<sup>49</sup>

## IA NA MEDICINA BASEADA EM EVIDÊNCIAS

A tradicional pirâmide da medicina baseada em evidências que coloca estudos observacionais na base da pirâmide não deve ser modificada tão cedo, entretanto, o uso de modelos matemático-computacionais cada vez mais robustos prometem evoluir muito nas inferências causais, a partir de dados observacionais. Esta evolução pode elevar o nível de evidência de análises observacionais o que poderá representar uma mudança significativa de paradigma na medicina baseada em evidências (especialmente nas questões em que a realização de um ensaio clínico tradicional seja inviável). Tendo em vista que os bancos de dados devem ser alimentados com dados saudáveis de forma contínua, haverá não só uma melhoria progressiva no desempenho dos algoritmos mas também uma informação atualizada de forma contínua ao longo do tempo.<sup>4</sup>

## RISCOS DA UTILIZAÇÃO DA INTELIGÊNCIA ARTIFICIAL NA CARDIOLOGIA

A IA tem um enorme potencial disruptivo, entretanto, como toda mudança de paradigma, há aspectos desafiadores de implicações relacionadas ao avanço da IA na medicina. A comunidade médica deve ter pleno conhecimento dos benefícios e riscos para que possa definir o que é útil e o que pode ser inapropriado na aplicação de sistemas de Inteligência Artificial na cardiologia.

A gestão de saúde baseada em informações geradas por estes dados pressupõe a utilização de dados saudáveis

com os melhores modelos existentes. Ao considerar uma eventual aplicação em larga-escala, deve-se checar se há adequada representação de minorias (étnicas, sociais) nos dados saudáveis que foram utilizados como base para os algoritmos de IA. Nesse sentido, a obtenção de dados saudáveis depende do incentivo das unidades de saúde para que seus profissionais tenham elevado rigor na obtenção e no preenchimento de dados (no caso de informações inseridas diretamente pelo paciente, deve-se ter o mesmo nível de cuidado).

Mesmo construídos com dados saudáveis, isto não quer dizer que esses modelos estão livres de erros. Deve-se sempre avaliar a possibilidade de sobreajuste (*overfitting*) dos modelos e o quanto esta eventual superestimativa da performance impactaria na aplicação prática do modelo. Embora busque-se sempre o erro mínimo, é importante ter em mente que são probabilidades (um modelo de IA que prevê com 98% de probabilidade de um paciente ter uma doença cardíaca, está implícito que há uma probabilidade de 2% de não ter esta enfermidade). Dessa forma, é importante que, mesmo como uma ferramenta de suporte, a IA não possa gerar uma “muleta” em que o médico se apoia ao ponto de perder sua capacidade de julgamento pois, nesse caso, um eventual erro no processo automatizado poderia induzir o profissional a conclusões incorretas. Este risco foi demonstrado em um estudo com 30 residentes cuja acurácia diagnóstica no laudo de ECG involuiu após a disponibilização de laudos automáticos incorretos.<sup>50</sup> Deve-se então reconhecer que mesmo como “apoio” ao médico, há problemas relacionados com a aplicação da IA na prática médica e, para mitigá-los, deve-se oferecer manter uma forte formação clínica aos médicos ao mesmo tempo que é oferecido o conhecimento adicional, que não é tradicionalmente encontrado em cursos regulares de medicina, sobre como utilizar de forma apropriada ferramentas de IA.

Além de modelos desenvolvidos com dados saudáveis, de alta precisão, continuamente aprimorados e corretamente aplicados, essas ferramentas também devem ter foco na detecção de erros e maior segurança na proteção de dados e dos processos utilizados em IA. Há de se estabelecer limites éticos para evitar o uso indevido destas ferramentas e garantir a segurança de dados.<sup>1</sup> Os métodos atuais de IA dependem muito de informações oriundas de registros médicos e, nesses casos, a necessidade de obtenção do consentimento informado é uma discussão frequente relacionada ao uso desses dados. Além disso, o uso indevido dessa ferramenta é sempre um risco, especialmente em sistemas de predição baseados em aspectos faciais cujo dado é de fácil acesso pelas empresas. Por exemplo, algoritmos de IA utilizados para detectar riscos de doenças cardíacas baseados em dados faciais poderiam ser utilizados por empresas de planos de saúde para avaliação do risco de um potencial cliente.

A proliferação de algoritmos de IA também tem levantado questionamentos sobre a responsabilização de desenvolvedores, reguladores, vendedores ou provedores de cuidados, caso um modelo cometa um erro e cause dano a um paciente, mesmo após ter sido clinicamente validado.<sup>11</sup> Atualmente, os médicos são responsabilizados quando não seguem as diretrizes recomendadas e o paciente sofre um dano. Sendo assim, se os médicos não confiarem nos algoritmos, passarão

a ignorá-los caso este indique algum tratamento diferente do que a diretriz recomenda, mesmo que esse tratamento seja personalizado e benéfico para um paciente específico. Entretanto, se o padrão de cuidado for alterado para que os médicos utilizem rotineiramente as ferramentas de IA, haverá um grande incentivo médico-legal para que essas recomendações sejam seguidas.

Mesmo seguindo os preceitos éticos vigentes e utilizando modelos apropriados, há ainda um grande risco na fase de aplicação de ferramentas de IA. Em uma primeira fase de utilização na prática no chamado “mundo real”, as ferramentas de IA devem atuar eminentemente como um apoio em tomadas de decisões e para refinar a precisão da estimativa prognóstica para ajudar no planejamento do cuidado do paciente. Avanços que possibilitem uma relação direta entre ferramentas de inteligência artificial e o paciente (sem a participação do médico) são ainda situações de maior preocupação. Além do risco de eventuais falhas em processos tecnológicos, há também falta de transparência no funcionamento de alguns tipos de IA em que não é possível explicar o “raciocínio” por trás do resultado final, como representado pelas chamadas caixas pretas existentes no *Deep Learning*. Entretanto, já convivemos e aceitamos certas situações como alguns casos de medicamentos e doenças que, apesar de tratarmos, não podemos explicar totalmente o mecanismo de ação dessas drogas e a fisiopatologia de certas enfermidades. Nessa zona de incertezas, é fundamental que tenhamos evidência clara e replicável de benefício em desfechos clinicamente relevantes, supervisão médica com apoio de modelos tradicionais na fase de implementação no “mundo real” e o desenvolvimento de medidas de contingência ou alertas para possíveis fragilidades que sejam detectadas ao longo do tempo (ex: processos auditáveis que possam gerar relatório de vieses e erros). Se não tomarmos essas precauções, corremos o risco de o paciente passar a não ter adequado entendimento e controle sobre o seu próprio cuidado.<sup>11</sup> Tendo os devidos cuidados, os pacientes deverão ganhar novas responsabilidades. Como por exemplo, um dispositivo inteligente poderá constantemente fazer recomendações ao paciente sobre sua saúde ou tratamento, sendo esperado que esse paciente siga as recomendações, sob pena de ser responsabilizado por desfechos clínicos desfavoráveis.

Finalmente, por mais que a IA possa ter equivalência ou até superioridade ao julgamento médico “padrão” em alguns cenários, há aspectos que são inerentes ao contato humano e que podem, inclusive, fazer parte do resultado da ação médica: empatia, intuição e compartilhamento de valores pessoais. Dessa forma, nenhum recurso tecnológico, até o momento, foi capaz de substituir o aspecto subjetivo da experiência clínica na tomada de decisões favoráveis ao paciente, exatamente, pela medicina não ser uma ciência exata. De qualquer maneira, há de se reconhecer os benefícios do avanço tecnológico das ferramentas de IA atualmente disponíveis. A negação destes avanços pode ser danosa ao

paciente assim como a dependência completa da tecnologia. Apesar da maior parte dos estudos focarem na comparação homem vs máquina, isso não se aplica para o mundo real. Não se deve ter receio da possível capacidade de que a IA possa substituir os médicos em suas tarefas pois, na história médica, o desenvolvimento de novas tecnologias não substituiu o especialista e, sim, resultou em uma maior velocidade do processo de trabalho e permitiu ao profissional atuar em outras questões importantes da especialidade (inclusive novas tarefas que surgiram após a implementação destas tecnologias). Tendo em vista que a função primordial seria fornecer melhor suporte para a tomada de decisão, a visão do médico mudará para um modelo de gestão assistencial baseada em dados e de forma personalizada possibilitaria alto desempenho (incluindo atualização constante) em uma cardiologia de precisão com necessidade de forte julgamento crítico e maior espaço para a relação médico-paciente. Desse modo, a combinação entre IA e o julgamento clínico visando o melhor interesse e a melhor experiência de seus pacientes é o caminho para obter os melhores desfechos com maior eficiência, ou seja, gerar valor em saúde.

## CONCLUSÃO

Embora ainda em desenvolvimento, a utilização da IA na cardiologia deixou a esfera teórica para se tornar uma realidade prática com diversas aplicações bem-sucedidas que permitem melhorias significativas do ponto de vista diagnóstico e terapêutico e em relação ao atendimento padrão (baseado exclusivamente na experiência individual médica). Esta revolução na área da saúde só será bem-sucedida se for aplicada de forma correta. Além da necessidade de dados saudáveis e modelos validados na população geral, há necessidade de ter vigilância contínua sobre o funcionamento destas ferramentas, incluindo fundamentalmente o respeito aos preceitos éticos vigentes. Uma vez respeitadas estas premissas, há possibilidade de aplicar a IA de forma apropriada na prática médica, mas, para isso, é necessário que a atividade médica seja transformada além de novos aspectos bioéticos, para que o médico tenha maior conhecimento matemático (particularmente o raciocínio probabilístico) e de gestão de saúde para que possa realizar o gerenciamento de cuidados baseados também em dados (relação médico-paciente-dados). Neste sentido, deve ser intrínseco ao profissional médico a importância da colaboração com o registro correto em prontuário para geração de novos dados saudáveis e o engajamento com senso crítico na busca de soluções para as dificuldades a serem superadas visando sempre o melhor interesse de seus pacientes.

## CONFLITOS DE INTERESSE

Os autores declaram não possuir conflitos de interesse na realização deste trabalho.

## REFERÊNCIAS

1. Souza Filho EM, Fernandes FA, Pereira NCA, Mesquita CT, Gismondi RA. Ethics, Artificial Intelligence and Cardiology. *Arq Bras Cardiol.* 2020;115(3):579-83.
2. Obermeyer Z, Emanuel EJ. Predicting the Future -Big Data, Machine Learning, and Clinical Medicine. *N Engl J Med.* 2016;375(13):1216-9.

3. Krittanawong C, Zhang H, Wang Z, Aydar M, Kitai T. Artificial intelligence in precision cardiovascular medicine. *J Am Coll Cardiol*. 2017;69(21):2657-64.
4. Souza Filho EM, Fernandes FA, Soares CLA. Artificial Intelligence in Cardiology: Concepts, Tools and Challenges - "The Horse is the One Who Runs, You Must Be the Jockey". *Arq Bras Cardiol*. 2020;114(4):718-25.
5. Dey D, Slomka PJ, Leeson P, Comaniciu D, Shrestha S, Sengupta PP, et al. Artificial intelligence in cardiovascular imaging: JACC State-of-the-Art review. *J Am Coll Cardiol*. 2019;73(11):1317-35.
6. Deo RC. Machine Learning in Medicine. *Circulation*. 2015;132(20):1920-30.
7. Paixão GMM, Santos BC, Araujo RM, Ribeiro MH, Moraes JL, Ribeiro AL. Machine Learning in Medicine: Review and Applicability. *Arq Bras Cardiol*. 2022;118(1):95-102.
8. Darcy AM, Louie AK, Roberts LW. Machine Learning and the Profession of Medicine. *JAMA*. 2016;315(6):551-2.
9. Jordan MI, Mitchell TM. Machine Learning: Trends, Perspectives, and Prospects. *Science*. 2015;349(6245):255-60.
10. Rajkomar A, Dean J, Kohane I. Machine Learning in Medicine. *N Engl J Med*. 2019;380(14):1347-58.
11. Rajpurkar P, Chen E, Banerjee O, Topol EJ. AI in health and medicine. *Nat Med*. 2022 Jan;28(1):31-38.
12. Shameer K, Johnson KW, Glicksberg BS, Dudley JT, Sengupta PP. Machine learning in cardiovascular medicine: are we there yet? *Heart*. 2018;104(14):1156-64.
13. Al'Aref SJ, Anchouche K, Singh G, Slomka PJ, Kolli KK, Kumar A, et al. Clinical applications of machine learning in cardiovascular disease and its relevance to cardiac imaging. *Eur Heart J*. 2018;40(24):1975-86.
14. Somashekhar SP, Sepulveda MJ, Puglielli S, Norden AD, Shortliffe EH, Rohit Kumar C, et al. Watson for Oncology and breast cancer treatment recommendations: agreement with an expert multidisciplinary tumor board. *Ann Oncol*. 2018;29(2):418-23.
15. Chen JH, Asch SM. Machine Learning and Prediction in Medicine -Beyond the Peak of Inflated Expectations. *N Engl J Med*. 2017;376(26):2507-9.
16. Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-Level Classification of Skin Cancer with Deep Neural Networks. *Nature*. 2017;542(7639):115-8.
17. Calabrese E, Villanueva-Meyer JE, Cha S. A fully automated artificial intelligence method for non-invasive, imaging-based identification of genetic alterations in glioblastomas. *Sci Rep*. 2020 Jul 16;10(1):11852.
18. Ribeiro AH, Ribeiro MH, Paixão GMM, Oliveira DM, Gomes PR, Canazart JA, et al. Automatic Diagnosis of the 12-lead ECG Using a Deep Neural Network. *Nat Commun*. 2020;11(1):1760.
19. Smith SW, Walsh B, Grauer K, Wang K, Rapin J, Li J, et al. A Deep Neural Network Learning Algorithm Outperforms a Conventional Algorithm for Emergency Department Electrocardiogram Interpretation. *J Electrocardiol*. 2019;52:88-95.
20. Martins JFBS, Nascimento ER, Nascimento BR, Sable CA, Beaton AZ, Ribeiro AL, et al. Towards automatic diagnosis of rheumatic heart disease on echocardiographic exams through video-based deep learning. *J Am Med Inform Assoc*. 2021 Aug 13;28(9):1834-42.
21. Tromp J, Seekings PJ, Hung CL, Iversen MB, Frost MJ, Ouwerkerk W, et al. Automated interpretation of systolic and diastolic function on the echocardiogram: a multicohort study. *Lancet Digit Health*. 2022 Jan;4(1):e46-e54.
22. Narang A, Bae R, Hong H, Thomas Y, Surette S, Cadieu C, et al. Utility of a Deep-Learning Algorithm to Guide Novices to Acquire Echocardiograms for Limited Diagnostic Use. *JAMA Cardiol*. 2021 Jun 1;6(6):624-32.
23. Perez MV, Mahaffey KW, Hedlin H, Rumsfeld JS, Garcia A, Ferris T, et al. Apple Heart Study Investigators. Large-Scale Assessment of a Smartwatch to Identify Atrial Fibrillation. *N Engl J Med*. 2019 Nov 14;381(20):1909-17.
24. Attia ZI, Noseworthy PA, Lopez-Jimenez F, Asirvatham SJ, Deshmukh AJ, Gersh BJ, et al. An artificial Intelligence-Enabled ECG Algorithm for the Identification of Patients with Atrial Fibrillation During Sinus Rhythm: A Retrospective Analysis of Outcome Prediction. *Lancet*. 2019;394(10201):861-7.
25. Rubin J, Parvaneh S, Rahman A, Conroy B, Babaeizadeh S. Densely connected convolutional networks for detection of atrial fibrillation from short single-lead ECG recordings. *J Electrocardiol*. 2018;51(6S):S18-S21.
26. Biton S, Gendelman S, Ribeiro AH, Miana G, Moreira C, Ribeiro ALP, et al. Atrial fibrillation risk prediction from the 12-lead electrocardiogram using digital biomarkers and deep representation learning. *European Heart Journal - Digital Health* 2021; 2(4):576-85.
27. Diamantino AC, Nascimento BR, Beaton AZ, Nunes MCP, Oliveira KKB, Rabelo LC, et al. Atrial fibrillation detection with a portable device during cardiovascular screening in primary care. *Heart*. 2020;106:1261-6.
28. Stehlik J, Schmalfuss C, Bozkurt B, Nativi-Nicolau J, Wohlfahrt P, Wegerich S, et al. Continuous Wearable Monitoring Analytics Predict Heart Failure Hospitalization: The LINK-HF Multicenter Study. *Circ Heart Fail*. 2020 Mar;13(3):e006513.
29. Fallahzadeh R, Pedram M, Ghasemzadeh H. SmartSock: a wearable platform for context-aware assessment of ankle edema. *Annu Int Conf IEEE Eng Med Biol Soc*. 2016 Aug;2016:6302-6.
30. Kwon JM, Lee Y, Lee Y, Lee S, Park J. An algorithm based on deep learning for predicting in-hospital cardiac arrest. *Am Heart Assoc*. 2018;7(13):pii: e008678.
31. Lin S, Li Z, Fu B, Chen S, Li X, Wang Y, et al. Feasibility of using deep learning to detect coronary artery disease based on facial photo. *Eur Heart J*. 2020;41(46):4400-11.
32. Weng SF, Reys J, Kai J, Garibaldi JM, Qureshi N. Can Machine-Learning Improve Cardiovascular Risk Prediction Using Routine Clinical Data? *PLoS One*. 2017;12(4):e0174944.
33. Raghunath SM, Cerna AU, Jing L, vanMaanen D, Stough JV, Hartzel D, et al. Deep Neural Networks Can Predict 1-Year Mortality Directly from ECG Signal, Even when Clinically Interpreted as Normal. *Circulation*. 2019;140(Suppl 1):A14425-.
34. Attia ZI, Friedman PA, Noseworthy PA, Lopez-Jimenez F, Ladewig DJ, Satam Get al. Age and Sex Estimation Using Artificial Intelligence From Standard 12-Lead ECGs. *Circ Arrhythm Electrophysiol*. 2019;12(9):e007284.
35. Lima EM, Ribeiro AH, Paixão GMM, Ribeiro MH, Pinto-Filho MM, Gomes PR, et al. Deep neural network-estimated electrocardiographic age as a mortality predictor. *Nat Commun*. 2021;12(1):5117.
36. Ambale-Venkatesh B, Yang X, Wu CO, Liu K, Hundley WG, McClelland R, et al. Cardiovascular Event Prediction by Machine Learning: The Multi-Ethnic Study of Atherosclerosis. *Circ Res*. 2017;121(9):1092-101.
37. Johnson KW, Soto JT, Glicksberg BS, Shameer K, Miotto R, Ali M, et al. Artificial Intelligence in Cardiology. *J Am Coll Cardiol*. 2018;71(23):2668-79.
38. Kang D, Dey D, Slomka PJ, Arsanjani R, Nakazato R, Ko H, et al. Structured Learning Algorithm for Detection of Nonobstructive and Obstructive Coronary Plaque Lesions from Computed Tomography Angiography. *J Med Imaging (Bellingham)*. 2015;2(1):014003.
39. Hae H, Kang SJ, Kim WJ, Choi SY, Lee JG, Bae Y, et al. Machine Learning Assessment of Myocardial Ischemia Using Angiography: Development and Retrospective Validation. *PLoS Med*. 2018;15(11):e1002693.
40. Nakajima K, Kudo T, Nakata T, Kiso K, Kasai T, Taniguchi Y, et al. Diagnostic accuracy of an artificial neural network compared with statistical quantitation of myocardial perfusion images: a Japanese multicenter study. *Eur J Nucl Med Mol Imaging*. 2017;44(13):2280-9.
41. Roguin A, Abu Dogosh A, Feld Y, Konigstein M, Lerman A, Koifman E. Early Feasibility of Automated Artificial Intelligence Angiography Based Fractional Flow Reserve Estimation. *Am J Cardiol*. 2021;139:8-14.

- 
42. Than MP, Pickering JW, Sandoval Y, Shah A, Tsanas A, Apple FS. Machine Learning to Predict the Likelihood of Acute Myocardial Infarction. *Circulation*. 2019;140(11):899-909.
  43. Berikol GB, Yildiz O, Özcan IT. Diagnosis of acute coronary syndrome with a support vector machine. *J Med Syst*. 2016;40(4):84.
  44. Katz DH, Deo RC, Aguilar FG, Selvaraj S, Martinez EE, Beussink-Nelson L, et al. Phenomapping for the Identification of Hypertensive Patients with the Myocardial Substrate for Heart Failure with Preserved Ejection Fraction. *J Cardiovasc Transl Res*. 2017;10(3):275-84.
  45. Zhang J, Gajjala S, Agrawal P, Tison GH, Hallock LA, Beussink-Nelson L, et al. Fully automated echocardiogram interpretation in clinical practice. *Circulation*. 2018;138(16):1623-35.
  46. Sengupta PP, Huang YM, Bansal M, Ashrafi A, Fisher M, Shameer K, et al. Cognitive Machine-Learning Algorithm for Cardiac Imaging: A Pilot Study for Differentiating Constrictive Pericarditis from Restrictive Cardiomyopathy. *Circ Cardiovasc Imaging*. 2016;9(6):e004330.
  47. Narula S, Shameer K, Omar AMS, Dudley JT, Sengupta PP. Machine-Learning Algorithms to Automate Morphological and Functional Assessments in 2D Echocardiography. *J Am Coll Cardiol*. 2016;68(21):2287-95.
  48. Martins JFBS, Nascimento ER, Nascimento BR, Sable CA, Beaton AZ, Ribeiro AL, et al. Towards automatic diagnosis of rheumatic heart disease on echocardiographic exams through video-based deep learning. *J Am Med Inform Assoc*. 2021;28(9):1834-42.
  49. Mortazavi BJ, Bucholz EM, Desai NR, Huang C, Curtis JP, Masoudi FA, et al. Comparison of machine learning methods with national cardiovascular data registry models for prediction of risk of bleeding after percutaneous coronary intervention. *JAMA Netw Open*. 2019;2(7):e196835.
  50. Shaw LJ. Can a Machine Learn Better Than Humans? *JACC Cardiovasc Imaging*. 2018;11(7):1010-1.



# CENTRO DE TREINAMENTO EM EMERGÊNCIAS CARDIOVASCULARES

Estamos de volta em março  
e com vagas limitadas

segundo todos os protocolos  
de saúde para sua segurança

Confira nossos cursos:

- ✓ ACLS
- ✓ ACLS REFRESH
- ✓ PALS
- ✓ PALS REFRESH
- ✓ SAVIC
- ✓ BLS
- ✓ FIRST AID

