

Suplemento da 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

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

 **SOCESP**
Associação de Cardiologistas 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

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
Salette 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
Lilia Nigro Maia

DEPARTAMENTOS / Biênio 2022–2023

DEPARTAMENTO EDUCAÇÃO FÍSICA
Diretor Executivo
Renato Lopes Pelaquim

Diretor(a) Científico(a)
Bruno do Nascimento Carvalho
Catarina de Andrade Barboza
Daniela Regina Agostinho

Secretário
Adriano dos Santos

DEPARTAMENTO FARMACOLOGIA
Diretora Executiva
Leiliane Rodrigues Marcatto

Diretor(a) Científico(a)
Adriana Castello Costa Girardi
Bruna Silva Fernandes D'angelo
Evandro José Cesarino

Secretária
Ana Lúcia Rego Fleury de Camargo

DEPARTAMENTO NUTRIÇÃO
Diretora Executiva
Juliana Tiekko Kato

Diretor(a) Científico(a)
Valeria Arruda Machado
Nagila Raquel Teixeira Damasceno
Luciene De Oliveira

Secretária
Claudia Stefani Marcilio

DEPARTAMENTO PSICOLOGIA
Diretora Executiva
Suzana Garcia Pacheco Avezum

Diretor(a) Científico(a)
Sara Alves de Resende
Priscila Maria Gabos
Talita Cepas Lobo

Secretário
Rafael Trevizoli Neves

DEPARTAMENTO ENFERMAGEM
Diretora Executiva
Rafaela Batista dos Santos Pedrosa

Diretor(a) Científico(a)
Ana Carolina Queiroz Godoy Daniel
Ana Maria Miranda Martins Wilson
Nathalia Malaman Galhardi

Secretária
Isabela Gomes Musa Dos Santos

DEPARTAMENTO FISIOTERAPIA
Diretora Executiva
Vera Lúcia dos Santos

Diretor(a) Científico(a)
Renata Trimer
Valéria Papa
Vanessa Marques Ferreira

Secretária
Solange Guizilini

DEPARTAMENTO ODONTOLOGIA
Diretora Executiva
Ana Carolina de Andrade Buhatem Medeiros

Diretor(a) Científico(a)
Frederico Buhatem Medeiros
Paulo Sérgio da Silva Santos
Raquel D'Aquino Garcia Caminha

Secretária
Mariana Sarmet Smiderle Mendes

DEPARTAMENTO SERVIÇO SOCIAL
Diretora Executiva
Suellen Cristina De Jesus Silva

Diretor(a) Científico(a)
Shirlei Cristina Pinto
Sérgio Miguel Pires De Oliveira
Letícia Andrade

Secretária
Elaine Maria Silva

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 –
Substitui Atualização Cardiológica, 1981 – 91

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), 4 (supl A)
2022, **32:** 1 (supl A)

ISSN 0103-8559 / 2595-4644
RSCESP 72594

WG100
CDU 616.1(05)

NLM W1

CDD₁₆ 616.105

ENFERMAGEM

- INTELIGÊNCIA ARTIFICIAL EM CARDIOLOGIA - ESTADO DA ARTE E PERSPECTIVAS FUTURAS..... 80**
ARTIFICIAL INTELLIGENCE IN CARDIOLOGY - STATE OF THE ART AND FUTURE PERSPECTIVES
Rita Simone Lopes Moreira, Vinicius Batista Santos, Fabiola Letícia Damascena Amador, Gabriele Cardoso Gonçalves, Vagner Rogério dos Santos
<http://dx.doi.org/10.29381/0103-8559/2022320180-4>

FARMACOLOGIA

- IMPACTO DA SAÚDE MÓVEL NA ADEÇÃO AO TRATAMENTO DE DOENÇAS CARDIOVASCULARES..... 85**
IMPACT OF MOBILE HEALTHCARE ON ADHERENCE TO CARDIOVASCULAR DISEASE TREATMENT
Alessandra Santos Menegon, Juliana Soprani, Adriana Castello Costa Girardi
<http://dx.doi.org/10.29381/0103-8559/2022320185-9>

NUTRIÇÃO

- INTELIGÊNCIA ARTIFICIAL NA AVALIAÇÃO DO CONSUMO ALIMENTAR: AVANÇOS NA ANÁLISE DA DIETA
E PREDIÇÃO DE DESFECHOS CARDIOVASCULARES 90**
ARTIFICIAL INTELLIGENCE IN DIETARY INTAKE ASSESSMENT: ADVANCES IN DIET ANALYSIS AND PREDICTION OF CARDIOVASCULAR OUTCOMES
Vanderlei Carneiro Silva, Dirce Maria Marchioni, Tânia Aparecida de Araujo, Angélica Castilho Alonso, Isabela Martins Benseñor
<http://dx.doi.org/10.29381/0103-8559/2022320190-7>

SERVIÇO SOCIAL

- ATUAÇÃO DO ASSISTENTE SOCIAL FRENTE A NOVAS TECNOLOGIAS DE INTELIGÊNCIA ARTIFICIAL:
DISPOSITIVOS DE ASSISTÊNCIA CIRCULATÓRIA MECÂNICA - DACM..... 98**
*PERFORMANCE OF THE SOCIAL WORKER IN THE FACE OF NEW ARTIFICIAL INTELLIGENCE TECHNOLOGIES:
MECHANICAL CIRCULATORY ASSIST DEVICES - MCAD*
Monica Pompiani, Ana Lucia da Silva Ribeiro, Ednalva Moreira da Silva, Suellen Cristina de Jesus Silva, Diego Vinicius Cassiano Barbosa
<http://dx.doi.org/10.29381/0103-8559/2022320198-102>

INTELIGÊNCIA ARTIFICIAL EM CARDIOLOGIA - ESTADO DA ARTE E PERSPECTIVAS FUTURAS

ARTIFICIAL INTELLIGENCE IN CARDIOLOGY - STATE OF THE ART AND FUTURE PERSPECTIVES



Clique para acessar
o Podcast

Rita Simone Lopes
Moreira^{1,2}
Vinicius Batista Santos^{1,2}
Fabiola Letícia Damascena
Amador¹
Gabriele Cardoso
Gonçalves¹
Vagner Rogério dos
Santos^{1,2}

1. Escola Paulista de Enfermagem da
Universidade Federal de São Paulo -
UNIFESP, São Paulo, SP, Brasil.

2. GAPEIS - Pesquisa Assistência,
Ensino e Pesquisa Interdisciplinar em
Inovação em Saúde. São Paulo, SP,
Brasil.

Correspondência:
Rita Simone Lopes Moreira
rita.simone@unifesp.br

RESUMO

A tecnologia tem impactado positivamente os cuidados de saúde, em especial nas doenças cardíacas, principal causa de mortes no mundo. Dentre as tecnologias que otimizam o manejo e o monitoramento do paciente, a inteligência artificial (IA) tem se destacado por melhorar a qualidade do cuidado, prever riscos e desfechos, estratificar doenças, apurar o julgamento do profissional através da previsão do suporte clínico, precisão diagnóstica, facilidade de interpretação de exames diagnósticos e inovação promissora nas práticas de enfermagem, tanto assistencialmente como no gerenciamento. O aprendizado de máquina e o aprendizado profundo poderão ser parceiros especialmente na insuficiência cardíaca, na qual a formação do profissional, sua atuação, internações recorrentes e adesão do paciente poderão ser monitoradas e corrigidas. Apesar de suas limitações, estudos futuros em IA garantem a verificação da melhora do prognóstico e do cuidado integral ao paciente, porém muito há de se desconstruir dentro do universo dos enfermeiros e das máquinas. A ideia da substituição do ser humano pela máquina permeia o pensamento de mecanização total da enfermagem para uma parceria promissora entre o humano e a máquina.

Descritores: Inteligência Artificial; Doenças Cardíacas; Enfermagem.

ABSTRACT

Technology has had a positive impact on health care, especially on cardiovascular disease, the leading cause of death in the world. Among the technologies that optimize patient management and monitoring, artificial intelligence (AI) has stood out for improving the quality of care, predicting risks and outcomes, stratifying diseases, and honing professional judgment through clinical support predictions, accurate diagnosis, easily interpretable diagnostic tests, and promising innovations in nursing practices, both in terms of care and management. Machine learning and deep learning can be partners, especially in heart failure, where a professional's training, their performance, recurrent hospitalizations, and patient adherence can be monitored and corrected. Despite their limitations, future AI studies will ensure verification of improvements in patient prognosis and integrated care, however there is much to be deconstructed within the universe of nurses and machines. The idea of substituting humans with machines permeates the thought process around the total mechanization of nursing for a promising partnership between humans and machines.

Keywords: Artificial Intelligence; Heart Disease; Nursing.

INTRODUÇÃO

As doenças cardiovasculares (DCVs) são as doenças não transmissíveis responsáveis pelo maior número de mortes em todo o mundo.¹ O desenvolvimento tecnológico e a recente evolução de mecanismos de inteligência artificial (IA) tem impactado de forma positiva o cenário dos sistemas de saúde e a avaliação de seus resultados.² A tecnologia que tem auxiliado a equipe de saúde na assertividade diagnóstica e na decisão terapêutica inundou a população em geral com informações de saúde,² influenciando nas práticas do autocuidado em doenças agudas e crônicas como: DCVs, câncer, diabetes, entre outras.³

Neste contexto, a tecnologia tem se tornado uma ferramenta fundamental para tais sistemas, configurando-se como um componente essencial na assistência, pois é por meio dela que o cuidado em saúde extrapola a barreira hospitalar e ambulatorial, otimizando o manejo e o monitoramento do paciente.² Esta realidade se materializa em diversas formas, como por exemplo, a telemedicina, aplicativos para telefonia móvel, robôs assistenciais, monitoração remota, bioeletrônica e da inteligência artificial (IA).²

INTELIGÊNCIA ARTIFICIAL NA SAÚDE

Na era do *big data*, aplicações que envolvem IA são uma realidade cada vez mais palpável. Neste aspecto, podemos definir de forma simplificada que estas tecnologias baseadas em IA são responsáveis por ensinar máquinas a “aprender, raciocinar, perceber, inferir, comunicar e tomar decisões como os humanos ou melhor que os humanos,”⁴ tornando-a inteligente,⁵ isto é, capaz de performar uma tarefa mental que normalmente requer inteligência humana.^{6,7}

A IA é um modelo emergente que pode melhorar os diagnósticos e modelos preditivos em saúde,³ aumentar a produtividade, impactar positiva e significativamente⁸ no cuidado à saúde e promover a saúde pública através das fontes digitais.⁵ Além disso, é capaz de impactar na qualidade do cuidado e os desfechos do paciente, facilitando a tomada de decisão clínica e evitando riscos desnecessários, como intervenções e tratamentos que não funcionaram anteriormente.² Outra importante contribuição da IA é em relação a vigilância epidemiológica, que tem se expandido com o avanço da ciência dos dados.⁵

SUPORTE À DECISÃO CLÍNICA

A IA tem sido implementada como incremento ao julgamento do profissional e predição do suporte clínico.⁶ Desta forma, o suporte à decisão clínica objetiva auxiliar os profissionais de saúde na tomada de decisão, no uso dos dados clínicos e no acesso ao conhecimento necessário para interpretação desses dados.⁸

Os sistemas que suportam tal função são compostos por *softwares* que combinam dados individuais de pacientes com uma base de dados computadorizada, baseada em IA, que gera recomendações específicas para o cuidado personalizado do paciente. Tal processo tem se tornado cada vez mais palpável e promissor, principalmente a partir da integração com os sistemas de prontuário eletrônicos.⁸

Conforme evidenciado em um estudo onde foi utilizado a IA para estratificar a resposta prognóstica aos betabloqueadores em pacientes com IC e FEVE reduzida, com o intuito de evitar os efeitos adversos a partir da identificação da resposta dos pacientes ao tratamento, foi identificado que os pacientes sem resposta terapêutica ao uso daqueles medicamentos tiveram o risco de morte reduzido, demonstrando que o uso da IA pode direcionar a decisão terapêutica, personalizando o tratamento a fim de melhorar o prognóstico do paciente e evitar os eventos adversos.⁶

PREVISÃO DE RISCO

Dentre as áreas da IA que tem se destacado nos últimos anos temos a IA Generalizada ou IA Forte. Neste campo, os algoritmos utilizam técnicas de aprendizado de máquina (AM) e aprendizado profundo (AP) como ferramenta, sendo capazes de descrever automaticamente padrões em conjuntos de dados.^{6,9,10} Tais algoritmos podem ser utilizados tanto em cenários não supervisionados, nos quais o conjunto de dados é composto apenas de covariáveis, ou em cenários supervisionados, em que a resposta de interesse é o fio condutor da análise.¹¹

A implementação do AM demanda uma estrutura regulatória integrada para a pesquisa, desenvolvimento e adoção, a fim de trazer diagnósticos mais precisos, diminuição da

realização de exames desnecessários e seleção de pacientes ideais para tratamentos dispendiosos.¹²

No campo da cardiologia, assim como na área da saúde em geral, modelos de previsão de risco podem estimar a probabilidade de um determinado desfecho ocorrer, constituindo uma valiosa ferramenta para previsão de riscos e detecção de eventos clínicos futuros,^{11,13,14} baseado em dados clínicos e fisiológicos.⁹

Neste aspecto, técnicas de AM podem ser utilizadas para auxiliar na estratificação das DCVs contribuindo para a assertividade do tratamento e prevenção a partir da melhor caracterização da população-alvo¹⁴ como observado em um estudo coorte com mais de 40.000 pacientes com IC na Suécia, que através da AM foi capaz de criar quatro novos fenótipos de IC nesta população, com características clinicamente reconhecíveis, forte valor prognóstico, identificando benefícios terapêuticos e resultados promissores.¹⁵

No entanto, Banerjee A et al.,¹⁴ observou limitações no uso da AM na estratificação das DCVs, com limitações em relação ao cenário clínico, principalmente no aspecto de número de covariáveis, comorbidades associadas, tamanho da população e localização geográfica, considerando a existência de lacunas associadas ao desenvolvimento, validação, replicabilidade, ética e eficácia na comunicação de modelos baseados em AM.¹⁶

Os modelos de previsão de risco atuais envolvem, em geral, uma análise dos fatores de risco transversais, que são compostos por comorbidades como hipertensão e diabetes associadas a hábitos adquiridos como tabagismos e sedentarismo. Apesar de apresentarem dados de assertividade que não podem ser ignorados, ainda são muito falhos.¹⁷ As abordagens baseadas em AM têm sido consideradas mais adequadas na previsão de resultados individuais, principalmente quando os dados dos prontuários estão associados a dados genéticos.¹⁷

Desta forma, o uso de técnicas de AM na previsão de desfechos como mortalidade e readmissão hospitalar têm se destacado. Shin et al.,¹³ ressalta em sua revisão sistemática um melhor desempenho das técnicas de AM em comparação aos modelos estatísticos convencionais na previsão desses desfechos em pacientes com insuficiência cardíaca (IC).¹⁵

Dos 15 estudos avaliados nesta revisão sistemática, 11 desses estudos reportaram melhores avaliações em readmissões hospitalares quando em uso da inteligência artificial e cinco de sete estudos reportaram melhores avaliações na predição de mortalidade, demonstrando de uma maneira geral que a IA apresenta maior força em prever desfechos na IC.¹³

SUPORTE DIAGNÓSTICO

Mecanismos de IA têm sido cada vez mais utilizados pelos sistemas de saúde globais, no campo do diagnóstico por imagem em cardiologia e suas aplicações estão direcionadas para áreas como: precisão diagnóstica, interpretação de imagens cardíacas, modelagem estatística da anatomia cardíaca,^{16,18} redução do tempo de análise, além de estratégias de tratamento personalizado e tomada de decisão.¹⁹

Desta forma, temos que as técnicas de IA têm sido aplicadas com sucesso para o diagnóstico de DCVs, como o infarto do miocárdio⁹ insuficiência cardíaca (IC), síndromes coronarianas agudas (SCA) e fibrilação atrial (FA).¹⁴ Tais

técnicas de IA, além de possibilitarem a avaliação da função cardíaca e melhora da qualidade da imagem, viabilizam a renderização de volume, projeção de intensidade máxima e reconstruções multiplanares curvas, com detecção e medição automáticas de estenose, conferindo maior precisão à interpretação das imagens.¹⁹

O uso do AM na análise de prontuários tem se tornado uma realidade cada vez mais palpável para previsão de incidência ou risco de DCVs, possibilitando a realização de avaliações complexas a partir da associação de fatores de riscos tradicionais, fatores bioquímicos, dados clínicos atualizados, dentre outros.²⁰ Tais associações são capazes de calibrar melhor os algoritmos de AM, refletindo em melhores resultados na previsão de risco e incidência de DCVs.²⁰

Em pacientes com DCVs, a partir do desenvolvimento da lesão, o coração inicia um fenômeno conhecido como remodelação cardíaca. Ao abordarmos este tópico de forma abrangente, podemos incluir um amplo espectro de processos fisiológicos que se estendem desde o processo de envelhecimento natural e remodelação adaptativa observada em atletas, a processos de remodelação adversa em cardiopatia hipertensiva e isquemia.¹⁸

Desta forma, é de fundamental importância a identificação de diferentes tipos de remodelação cardíaca e de variáveis associadas (fatores ambientais, comorbidades etc.), de forma a auxiliar no manejo da doença e previsão de eventos adversos. É neste ensejo que o uso de técnicas de diagnóstico por imagem como ecocardiografia, tomografia computadorizada (TC) e ressonância magnética (RM) associados a técnicas de IA impactam no cuidado ao paciente.¹⁸

Neste aspecto, a criação de atlas dinâmicos de anatomia cardíaca se configuram como uma importante área a ser explorada, uma vez que muitas das patologias cardíacas se manifestam através de alterações na motricidade, como proposto por Gilbert K et al., que em sua revisão expôs formas de integração entre atlas estatísticos e estruturas de AM, repercutindo no aumento da interpretabilidade dos sistemas de IA a longo prazo.¹⁸

Em decorrência do número cada vez maior de pacientes com doenças cardiovasculares e o crescimento na necessidade de estudos ecocardiográficos que são realizados tanto no laboratório como a beira do leito (*point of care*), técnicas de AM estão sendo utilizadas para reconhecimento, quantificação e identificação de padrões ecocardiográficos normais e alterados.²¹

No aspecto da aquisição de imagens ecocardiográficas, com a visualização do coração por diversos ângulos, vemos mais uma aplicação de IA, que pode ser empregada tanto na reconstrução das imagens obtidas quanto no reconhecimento das estruturas anatômicas, na classificação e comparação com padrões pré-definidos.²¹

Desta forma, a AM pode ser usada para medir e interpretar automaticamente imagens ecocardiográficas, através da quantificação das câmaras cardíacas, da mensuração da veia cava inferior e de sua distensibilidade para avaliação da volemia, o que mostrou melhorar a eficiência e consistência da interpretação das imagens.²²

ELETROCARDIOGRAFIA

O eletrocardiograma (ECG) é um exame simples que constitui uma valiosa ferramenta no diagnóstico de DCVs. E a associação desta tecnologia com mecanismos de IA tem se

tornado uma realidade cada vez mais palpável, tendo em vista o processo de transição dos ECGs analógicos para digitais e a possibilidade de análises computadorizadas destes exames.^{23,24}

Os métodos de AM têm sido considerados mais precisos e confiáveis na interpretação de ECGs quando comparados a eletrocardiogramas interpretados por computador (método tradicional).²¹ A análise de ECGs através de redes neurais profundas (RNP), que constituem uma área promissora da AM, tem se destacado na perspectiva de classificação de imagens, principalmente com modelos de aprendizagem supervisionados. No entanto, para que tais resultados sejam aplicáveis à prática clínica, é de fundamental importância o uso de bancos de dados robustos, com dados rotulados e verificáveis.²³

Ademais, observamos a aplicação da IA não apenas em contextos direcionados a interpretação e classificação de imagens de ECGs, mas também em sistemas de monitoramento eletrocardiográficos. Tais sistemas têm se difundido na última década, rompendo as fronteiras hospitalares e se disseminado em ambientes ambulatoriais, domésticos e até mesmo em contextos remotos.²⁴

Neste cenário, destaca-se a aplicação de sistemas de monitoramento eletrocardiográfico em ambientes domésticos, a partir de redes de acompanhamento remotas, os quais podem ser segmentados em: telemonitoramento, monitoramento contínuo vestível e monitoramento domiciliar de idosos.²⁴

INTELIGÊNCIA ARTIFICIAL NA ENFERMAGEM

A colaboração entre a enfermagem e áreas da engenharia tem começado a se consolidar, reforçando práticas de cooperação interdisciplinares. Zhou et al.,²⁵ explorou este campo em uma revisão de escopo, trazendo dados promissores a respeito da produção desenvolvida a partir das contribuições entre essas áreas. Ainda, o autor destaca que através da transição de conhecimentos, observou-se inovação nas práticas de enfermagem com o uso de tecnologias e inteligência artificial.²⁵

A relação humano-máquina é extremamente promissora: máquinas executam tarefas muitas vezes com precisão e acurácia melhor do que humanos, porém os dados necessitam de interpretação e julgamento clínico.²⁵ Essas duas últimas tarefas têm sido incorporadas por técnicas de AM supervisionadas e não-supervisionadas, no entanto a implementação desses dados na prática clínica e nas condutas de enfermagem ainda exigem a participação humana.^{10,11,25}

A Enfermagem de uma maneira geral ainda produz pouco conhecimento em relação a IA sendo um campo ainda em desenvolvimento. Amezcua, em seu editorial, traz algumas reflexões a respeito desta situação: uma das hipóteses segundo o autor seria que as enfermeiras temem perder espaço e assim serem suprimidas pelas máquinas. No entanto, vale ressaltar que muitas das nossas tarefas já são alicerçadas em ferramentas tecnológicas, como controles para monitoramento.²⁶

Desta forma, é importante que não haja uma competição com a tecnologia, mas sim a incorporação à prática, explorando seus benefícios, ampliando o campo de atuação com enfermeiros clínicos, programadores e engenheiros para desenvolvimento de tecnologias, especialmente ligadas a Inteligência Artificial.^{25,26}

Enfermagem no gerenciamento da Inteligência Artificial

Obviamente, as atividades que puderem ser compostas pelo universo “das máquinas” ocorrerá, porém discutir sobre nosso trabalho, especialmente no que tange ao cuidado humanizado também deve estar em pauta. E entender que as máquinas serão submetidas a um ser humano, que irá programá-las é uma discussão bastante intrigante e polêmica, porém estabelecer metas e assim empoderá-las em detrimento do nosso cuidado será impossível.²⁷

Assim, é premente que consideremos a introdução da tecnologia associada à Inteligência Artificial em nossa prática clínica e em nossa formação, pois não poderemos estar fora desta “explosão”, como o uso das tecnologias avançadas associada ao cuidado, entendendo que a relação interpessoal e a relação paciente/profissional sempre será nutrida por sentimentos, que poderão até ser detectados por máquinas, mas nunca substituirá o toque ou a palavra.²⁶

A IA poderá modificar a forma como os enfermeiros despendem tempo prestando assistência ao paciente, mas é importante lembrar que a necessidade de enfermeiros permanecerá. A experiência, o conhecimento e as habilidades da enfermagem trarão modificações no pensar desta ciência, principalmente no que diz respeito à integração de informações a respeito do cuidado, no treinamento em saúde e na forma com que a enfermagem pensará o cuidado apoiado pela IA, e não substituída por ela.²⁶

A IA na enfermagem está sendo utilizada com o objetivo de prever a necessidade de cuidado, os riscos de deterioração clínica que implicam em maior vigilância no cuidado em pacientes hospitalizados ou na comunidade e o risco em desenvolver alguns fenômenos tratáveis por ações de enfermagem, como por exemplo, a lesão por pressão, no raciocínio clínico para a identificação de fenômenos tratáveis por ações de enfermagem (diagnósticos de enfermagem), para o estabelecimento de metas e escolha das melhores ações para o alcance de resultados positivos em saúde e até no uso de robôs com IA para auxiliar pessoas idosas no autocuidado e na interação social.^{26,27}

Em uma revisão de escopo de literatura sobre o uso da IA nos domínios da enfermagem foram selecionados 131 artigos que emergiram os seguintes assuntos: utilização de robôs para auxílio no autocuidado de idosos e para interação social, utilização de robôs para realização de atividades de autocuidado, análise preditiva de risco, sistemas de apoio à decisão clínica, gestão dos serviços de enfermagem em relação a realização escalas mensais e diárias de enfermagem, casas inteligentes e chatbots virtuais de saúde, novos métodos de pesquisa na enfermagem.²⁵

LIMITAÇÕES DOS USOS DA INTELIGÊNCIA ARTIFICIAL

A implementação da IA na prática clínica se constitui ainda como um desafio.⁹ Uma das limitações do uso da IA é o efeito

black-box, que está relacionada à falta de transparência dessa técnica. Esse efeito significa que os dados são acessíveis, mas os processos e os caminhos que levaram a determinada conclusão não é visualizável, o que gera desconfiança no seu uso.⁶ Além disso, a função, confiabilidade, transparência e responsabilidade dos profissionais na tomada de decisão, manuseio de dados pessoais, monitoramento contínuo de eventos e sistemas adversos de IA, falha, segurança cibernética e atualização do sistema também geraram descrédito na implementação e adoção dessa tecnologia.¹²

PERSPECTIVAS FUTURAS

Uma avaliação prospectiva em um contexto randomizado agora garante avaliar se essas abordagens são valiosas na prática diária para melhorar o prognóstico do paciente, particularmente em condições como IC, que permanece como principal condição associada ao custo da assistência à saúde e à pior qualidade de vida do paciente.^{6,28,29} Felizmente, a recente disponibilidade de bancos de dados públicos incentiva os pesquisadores a buscar novos algoritmos de IA, mas ainda é necessária validação com estudo multicêntrico.¹⁹

Já no que se refere à tecnologia diagnóstica, a avaliação do ECG com o suporte da IA foi além da avaliação fisiológica da doença para a avaliação do estado psicológico para melhor direcionamento do cuidado à saúde mental. Essa revolução decorre da geração de percepções a partir da coleta e processamento dos sinais, protegendo a privacidade e emoções do indivíduo.²⁴

CONSIDERAÇÕES FINAIS

Há um crescente reconhecimento de que as tecnologias emergentes de inteligência artificial (IA) terão um impacto significativo na prática das profissões em saúde em um futuro próximo. Aprendizado de máquinas, Inteligência artificial e outros modelos dentro desta nova e inevitável ciência tecnológica poderão trazer grandes oportunidades e recursos de melhoria de trabalho para os enfermeiros, melhor acurácia para nossos diagnósticos de enfermagem. Da mesma forma, estarão ao nosso alcance modelos preditivos para avaliações, que consequentemente trarão benefícios aos pacientes.

Devemos desconstruir o pensamento de que máquinas nos substituirão: devemos lembrar que a ciência da enfermagem é conceituada pela “arte e ciência do cuidar”. E nesta perspectiva, nenhum modelo, algoritmo ou robô poderá atingir esta tecnologia.

CONFLITOS DE INTERESSE

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

REFERÊNCIAS

1. GBD 2016 Causes of Death Collaborators. Global, regional, and national age-sex specific mortality for 264 causes of death, 1980-2016: A systematic analysis for the Global Burden of Disease Study 2016. *Lancet*. 2017;390(10100):1151-210. Available from: <https://pubmed.ncbi.nlm.nih.gov/28919116/>
2. Kataria S, Ravindran V. Digital health: a new dimension in rheumatology patient care. *Rheumatol Int*. 2018;38(11):1949-57. Available from: <https://pubmed.ncbi.nlm.nih.gov/29713795/>
3. Baig MM, GholamHosseini H, Moqem AA, Mirza F, Lindén M. A Systematic Review of Wearable Patient Monitoring Systems

- Current Challenges and Opportunities for Clinical Adoption. *J Med Syst.* 2017;41(7):115. Available from: <https://pubmed.ncbi.nlm.nih.gov/28631139/>
4. Mavragani A, Sampri A, Sypsa K, Tsagarakis KP. Integrating Smart Health in the US Health Care System: Infodemiology Study of Asthma Monitoring in the Google Era. *JMIR Public Health Surveill.* 2018;4(1):e24. Available from: <https://pubmed.ncbi.nlm.nih.gov/29530839/>
 5. Thiébaud R, Cossin S. Artificial Intelligence for Surveillance in Public Health. *Yearb Med Inform.* 2019;28(1):232–4. Available from: <https://pubmed.ncbi.nlm.nih.gov/31419837/>
 6. Aleman R, Patel S, Sleiman J, Navia J, Sheffield C, Brozzi NA. Cardiogenic shock and machine learning: A systematic review on prediction through clinical decision support softwares. *J Card Surg.* 2021;36(11):4153–9. Available from: <https://pubmed.ncbi.nlm.nih.gov/34463361/>
 7. Karwath A, Bunting KV, Gill SK, Tica O, Pendleton S, Aziz F, et al. Redefining β -blocker response in heart failure patients with sinus rhythm and atrial fibrillation: a machine learning cluster analysis. *Lancet.* 2021;398(10309):1427–35. Available from: <https://pubmed.ncbi.nlm.nih.gov/34474011/>
 8. Demner-Fushman D, Chapman WW, McDonald CJ. What can natural language processing do for clinical decision support? *J Biomed Inform.* 2009;42(5):760–72. Available from: <https://pubmed.ncbi.nlm.nih.gov/19683066/>
 9. Stewart J, Lu J, Goudie A, Bennamoun M, Sprivilis P, Sanfilippo F, et al. Applications of machine learning to undifferentiated chest pain in the emergency department: A systematic review. *Bivona G, editor. PloS One.* 2021;16(8):e0252612. Available from: <https://pubmed.ncbi.nlm.nih.gov/34428208/>
 10. Ludermir TB. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. *Estud Av.* 2021;35(101):85–94. Available from: <https://www.scielo.br/j/ea/a/wXBdv8yHBV9xHz8qG5RCgZd/>
 11. Santos HG, Nascimento CF, Izbicki R, Duarte YAO, Chiavegatto Filho ADP. Machine learning para análises preditivas em saúde: exemplo de aplicação para prever óbito em idosos de São Paulo, Brasil. *Cad Saúde Pública.* 2019;35(7):e00050818 Available from: <http://cadernos.ensp.fiocruz.br/static/arquivo/1678-4464-csp-35-07-e00050818.pdf>
 12. Bazoukis G, Stavrakis S, Zhou J, Bollepalli SC, Tse G, Zhang Q, et al. Machine learning versus conventional clinical methods in guiding management of heart failure patients—a systematic review. *Heart Fail Rev.* 2021;26(1):23–34. Available from: <https://pubmed.ncbi.nlm.nih.gov/32720083/>
 13. Shin S, Austin PC, Ross HJ, AbdelQadir H, Freitas C, Tomlinson G, et al. Machine learning vs. conventional statistical models for predicting heart failure readmission and mortality. *ESC Heart Fail.* 2021;8(1):106–15. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7835549/>
 14. Banerjee A, Chen S, Fatemifar G, Zeina M, Lumbers RT, Mielke J, et al. Machine learning for subtype definition and risk prediction in heart failure, acute coronary syndromes and atrial fibrillation: systematic review of validity and clinical utility. *BMC Med.* 2021;19(1):85. Available from: <https://pubmed.ncbi.nlm.nih.gov/33820530/>
 15. Ahmad T, Lund LH, Rao P, Ghosh R, Warier P, Vaccaro B, et al. Machine Learning Methods Improve Prognostication, Identify Clinically Distinct Phenotypes, and Detect Heterogeneity in Response to Therapy in a Large Cohort of Heart Failure Patients. *J Am Heart Assoc.* 2018;7(8):e008081. Available from: <https://pubmed.ncbi.nlm.nih.gov/29650709/>
 16. Long Q, Ye X, Zhao Q. Artificial intelligence and automation in valvular heart diseases. *Cardiol J.* 2020;27(4):404–20. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8016001/>
 17. Zhao J, Feng Q, Wu P, Lupu RA, Wilke RA, Wells QS, et al. Learning from Longitudinal Data in Electronic Health Record and Genetic Data to Improve Cardiovascular Event Prediction. *Sci Rep.* 2019;9(1):717. Available from: <https://pubmed.ncbi.nlm.nih.gov/30679510/>
 18. Gilbert K, Mauger C, Young AA, Suinesiaputra A. Artificial Intelligence in Cardiac Imaging With Statistical Atlases of Cardiac Anatomy. *Front Cardiovasc Med.* 2020;7:102. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7338378/>
 19. Jiang B, Guo N, Ge Y, Zhang L, Oudkerk M, Xie X. Development and application of artificial intelligence in cardiac imaging. *Br J Radiol.* 2020;93(1113):20190812. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7465846/>
 20. 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. Available from: <https://pubmed.ncbi.nlm.nih.gov/28376093/>
 21. Chang A, Cadaret LM, Liu K. Machine Learning in Electrocardiography and Echocardiography: Technological Advances in Clinical Cardiology. *Curr Cardiol Rep.* 2020;22(12):161. Available from: <https://pubmed.ncbi.nlm.nih.gov/33037949/>
 22. Chan JSK, Tse G, Zhao H, Luo X, Jin C, Kam K, et al. Echocardiography update for primary care physicians: a review. *Hong Kong Med J.* 2020;26(1):44–55. Available from: <https://pubmed.ncbi.nlm.nih.gov/32051329/>
 23. 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. Available from: <https://pubmed.ncbi.nlm.nih.gov/32273514/>
 24. Serhani MA, El Kassabi HT, Ismail H, Nujum Navaz A. ECG Monitoring Systems: Review, Architecture, Processes, and Key Challenges. *Sensors.* 2020;20(6):1796. Available from: <https://pubmed.ncbi.nlm.nih.gov/32213969/>
 25. Zhou Y, Li Z, Li Y. Interdisciplinary collaboration between nursing and engineering in health care: A scoping review. *Int J Nurs Stud.* 2021;117:103900. Available from: <https://pubmed.ncbi.nlm.nih.gov/33677250/>
 26. Amezcua M. Tecnologías avanzadas e Inteligencia artificial: oportunidades para una Enfermería con competencias ampliadas. *Index Enferm.* 2019;28(3):97–9. Available from: http://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1132-12962019000200001
 27. Arandojo Morales MI. Nuevas Tecnologías y nuevos retos para el profesional de enfermería. *Index Enferm.* 2016;25(1–2):38–41. Available from: http://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1132-12962016000100009
 28. Awan SE, Sohel F, Sanfilippo FM, Bennamoun M, Dwivedi G. Machine learning in heart failure: ready for prime time. *Cur Opin Cardiol.* 2018;33(2):190–5. Available from: <https://pubmed.ncbi.nlm.nih.gov/29194052/>
 29. Karanasiou GS, Tripoliti EE, Papadopoulos TG, Kalatzis FG, Goletsis Y, Naka KK, et al. Predicting adherence of patients with HF through machine learning techniques. *Healthc Technol Lett.* 2016;3(3):165–70. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5048333/>

IMPACTO DA SAÚDE MÓVEL NA ADESÃO AO TRATAMENTO DE DOENÇAS CARDIOVASCULARES

IMPACT OF MOBILE HEALTHCARE ON ADHERENCE TO CARDIOVASCULAR DISEASE TREATMENT



Clique para acessar
o Podcast

Alessandra Santos
Menegon¹
Juliana Soprani¹
Adriana Castello Costa
Girardi¹

1. Instituto do Coração -InCor. São Paulo, SP, Brasil.

Correspondência:
Alessandra Santos Menegon.
alessandra.s.menegon@gmail.com

RESUMO

A baixa adesão ao tratamento medicamentoso é associada a resultados negativos para a saúde. Estima-se que a não adesão à farmacoterapia ocorre em mais de 60% dos pacientes com doença cardiovascular. Para melhorar a adesão ao tratamento uma nova ferramenta tem adquirido destaque: a saúde móvel (mHealth). Com a disseminação dos dispositivos móveis e da internet, principalmente após o início da pandemia de COVID-19, o impacto que a mHealth poderia ter sobre a saúde no Brasil e no mundo é evidente, porém evidências que apoiam a eficácia dessa nova tecnologia para melhorar a adesão ao tratamento medicamentoso ainda não está clara. O objetivo desta revisão foi avaliar as evidências de como a mHealth pode influenciar a adesão dos pacientes com doença cardiovascular à medicação. A busca pelos estudos foi feita nas bases de dados PubMed, Scielo e LILACS. A maioria dos estudos apresentam resultados promissores em termos da capacidade da mHealth. Porém, parte dos estudos também apresenta ressalvas devido aos resultados não significativos, justificados em grande parte, pelo número pequeno de participantes e o curto tempo de duração do estudo. Sendo assim, precisamos de evidências mais fortes de estudos bem projetados e implementados, com tamanhos maiores de amostra e maior duração de intervenção e acompanhamento, para confirmar o real benefício da mHealth.

Descritores: Adesão à Medicação; Doenças Cardiovasculares; Saúde Móvel.

ABSTRACT

Poor adherence to drug treatment is associated with negative health effects. Non-adherence to pharmacotherapy is estimated to occur in more than 60% of patients with cardiovascular disease. A new tool to improve treatment adherence has attracted attention: mHealth. With the expansion of mobile devices and the Internet, especially after the start of the COVID-19 pandemic, the impact that mHealth could have on healthcare in Brazil and around the world is obvious, but the evidence supporting the effectiveness of this new technology in improving drug treatment compliance is not yet clear. The aim of this review was to evaluate evidence of how mHealth can influence drug adherence in patients with cardiovascular disease. A search for studies was performed in the PubMed, SciELO and LILACS databases. Most of the studies show promising results in terms of mobile healthcare capacity. However, some studies also have reservations due to non-significant results, largely justified by the small number of participants and the short duration of the study. Therefore, we need stronger evidence from well-designed and implemented studies with larger sample sizes and longer intervention and follow-up periods to confirm the real benefit of mHealth.

Keywords: Medication Adherence; Cardiovascular Diseases; Mobile Health.

INTRODUÇÃO

A baixa adesão ao tratamento medicamentoso leva a resultados negativos para a saúde, estando associada a diversos fatores, como: aumento da frequência de internações hospitalares, aumento da morbidade, resistência a medicamentos, aumento da complexidade de esquemas farmacoterapêuticos e aumento dos custos com saúde.¹ Estima-se que a baixa

adesão ao tratamento resulta em aproximadamente 33 a 69% das internações relacionadas a medicamentos e representa um gasto anual de US\$ 100 bilhões.¹ Portanto, a adesão é crucial e deve ser promovida. A Organização Mundial da Saúde (OMS) identificou a não adesão aos medicamentos como um problema prioritário de saúde evitável e uma barreira fundamental para melhorar os resultados clínicos.² Estima-se

que a não adesão ao tratamento medicamentoso ocorre em mais de 60% dos pacientes com doença cardiovascular, uma das principais causas de morbimortalidade em todo o mundo.^{3,4}

Embora a não adesão medicamentosa possa ser atribuída ao esquecimento, barreiras à comunicação, fatores socioeconômicos e motivação,^{3,5} a não persistência ao tratamento também pode resultar de dificuldades financeiras, medo de efeitos colaterais, crenças falsas sobre doença ou tratamento e falta de entendimento sobre a finalidade do medicamento.⁶ Como resultado, é necessária uma abordagem multimodal em relação à ingestão de medicamentos para melhorar o resultado entre pacientes com condições crônicas.

Para melhorar a adesão aos medicamentos, classicamente utiliza-se intervenções comportamentais, como caixas de comprimidos ou embalagens de blister, aconselhamento e seguimento de pacientes pelo farmacêutico e telefonemas de acompanhamento dos prestadores de cuidados.⁷ Porém, nos últimos anos uma nova ferramenta tem adquirido destaque: a saúde móvel (*mHealth*).

A disseminação da internet via dispositivos móveis levou ao surgimento e difusão da *mHealth*. Embora não exista, segundo a OMS, uma definição padronizada do novo conceito, pode-se entender *mHealth* como a oferta de serviços médicos e/ou de Saúde Pública que se valem do apoio tecnológico de dispositivos móveis, como telefones celulares, sensores e outros equipamentos vestíveis ou *Wearable* (dispositivos diretamente conectados ao usuário). O objetivo da *mHealth* é a expansão a cobertura de saúde, facilitando o processo de tomada de decisão e melhoria da gestão de doenças crônicas.^{8,9}

Apesar da *mHealth* apresentar crescente desenvolvimento nos últimos cinco anos, seu uso na prestação de serviços de saúde aumentou expressivamente durante a pandemia de COVID-19. Com a necessidade de minimizar a exposição de pacientes e profissionais de saúde em ambientes de atendimento, foi necessário substituir as consultas presenciais tradicionais pelos serviços clínicos remotos.¹¹

Até o final de 2018, 67% da população global (5,1 bilhões de pessoas) assinava serviços de Internet móvel, número que deve aumentar para 71% (5,8 bilhões de pessoas) até 2025.¹⁰ No Brasil, um levantamento da Fundação Getúlio Vargas de São Paulo declarou que há 242 milhões de celulares ativos no Brasil, ou seja, existe mais de um celular por pessoa considerando a população atual do país.¹² O impacto que a *mHealth* pode ter sobre a saúde no Brasil e no mundo é evidente, porém evidências que apoiem a eficácia dessas novas tecnologias para melhorar a adesão ao tratamento medicamentoso ainda não estão claras. Os resultados de intervenções derivadas de *mHealth* são contraditórios, enquanto alguns demonstram resultados modestos e inespecíficos,^{13,14} outros estudos demonstraram o impacto positivo da saúde móvel no comportamento relacionado à adesão ao tratamento.^{15,16} Neste contexto, nosso objetivo é revisar as evidências de como a *mHealth* pode influenciar a adesão medicamentosa em pacientes com doença cardiovascular.

METODOLOGIA

O presente trabalho refere-se a um artigo de revisão acerca do impacto da *mHealth* sobre a adesão medicamentosa em pacientes com doença cardiovascular.

A busca pelos estudos foi feita nas bases de dados PubMed, Scielo e LILACS, a partir de combinações dos termos "*mHealth*", "cardiovascular" e "*adherence*". Foram avaliados estudos em Inglês, Português e Espanhol, publicados nos últimos 10 anos.

AS VANTAGENS E A EXTENSÃO DA MHEALTH NO MUNDO

A tecnologia *mHealth* é de baixo custo, fácil acesso e fácil de usar, e tem o potencial de atingir uma população global nunca antes observada em serviços de saúde. No primeiro trimestre de 2021, havia cerca de 53.054 aplicativos *mHealth* disponíveis na Google Play Store, número significativamente maior em relação ao mesmo período de 2015, no qual havia cerca de 23.955 aplicativos disponíveis na plataforma.¹⁷ Com a facilidade de aquisição de conhecimento por meio da internet móvel, é inegável que essa tecnologia será parte integrante do futuro dos cuidados com a saúde. Essa foi a conclusão de uma análise nos Estados Unidos que demonstrou que um em cada três proprietários de celulares usavam seu dispositivo para procurar aconselhamento sobre cuidados de saúde e 19% baixavam aplicativos relacionados à saúde em seu dispositivo. Na faixa etária de 18 a 29 anos, três quartos das pessoas avaliadas usavam o smartphone para buscar informações sobre uma condição de saúde.¹⁸

Dada a crescente popularização de smartphones em grupos com baixo status socioeconômico, que também têm pouco acesso a cuidados médicos e altos fatores de risco cardiovascular, aplicativos para smartphones relacionados à saúde poderiam oferecer uma oportunidade de superar barreiras tradicionais para acessar e melhorar os resultados de doenças cardiovasculares (DCV).¹⁹ Da prevenção primária à secundária, a *mHealth* poderia auxiliar a aumentar a adesão ao tratamento, tanto de intervenções farmacológicas, quanto de não farmacológicas. Mas para isso, essa tecnologia precisa ser simples, com uma mensagem clara e concisa com a qual o usuário possa entender e se relacionar diariamente, tendo em vista que o perfil do paciente com DCV é composto por idosos com, muitas vezes, limitações físicas, incluindo destreza e visão manuais, possibilidade de uma função cognitiva diminuída e relutância em mudar o comportamento.¹⁹ A tecnologia deve visar mudanças comportamentais e abordar especificamente fatores de risco modificáveis, além de auxiliar na adesão ao tratamento. Deve haver um aspecto da medicina personalizada com feedback direto ao usuário, lembretes de rotina, educação, recompensas e reforço positivo para continuar o comportamento proposto.¹⁹

TIPOS DE FERRAMENTAS UTILIZADAS EM MHEALTH

Intervenções que incorporam *mHealth* podem empregar diferentes recursos das tecnologias móveis, incluindo sistemas de mensagens curtas (SMS), chamadas de voz, aplicativos para telefones móveis (especializados em saúde ou não), sistemas de posicionamento global e Bluetooth.²⁰ Várias revisões sistemáticas já foram realizadas para avaliar a eficácia das intervenções em saúde móvel sobre práticas e resultados de saúde para condições crônicas.^{16,21-24} Ao avaliá-las, podemos observar que maioria dos estudos utilizam

mensagens de texto em combinação ou não com outras intervenções. O conteúdo das mensagens de texto geralmente inclui informações sobre educação em saúde, lembretes para tomar medicamentos prescritos e mensagens interativas automatizadas, modificadas de acordo com a população de pacientes, cultura, idioma, educação e ambiente social.^{16,21,22}

Dentro do contexto das doenças cardiovasculares, diversos estudos utilizam a ferramenta de SMS. Park et al.,²⁵ usaram o SMS para lembrar e/ou educar os participantes com doença arterial coronariana sobre o uso de medicamentos cardiovasculares. As mensagens de texto enviadas eram personalizadas e possibilitavam que o paciente fizesse perguntas. Quilici et al.,²⁶ usaram lembretes diários por SMS para adesão à aspirina em pacientes submetidos a angioplastia após síndromes coronárias agudas. Fang et al.,²⁷ usou mensagens de texto junto com um serviço online de mensagens em plataforma de acesso aberto. Ele enviava informações relacionadas à condição da doença e adesão ao medicamento aos pacientes em intervalos regulares, sob supervisão de uma equipe multiprofissional e médico. Buis et al.,²⁸ enviava mensagens, em horários personalizados para cada paciente, com lembretes diários sobre medicamentos e recomendações para o gerenciamento da hipertensão.

As intervenções por SMS requerem o hardware menos sofisticado e podem ser usadas para transmitir informações simples para os pacientes em seus telefones pessoais, provavelmente por este motivo são as ferramentas mais comuns ao envolver *mHealth*. Porém, alguns estudos apontam para o cuidado em relação à frequência das mensagens enviadas, pois, se muito frequentes, podem causar fadiga nos pacientes. Portanto, são necessárias avaliações prévias para determinar a frequência ideal de intervenções específicas em saúde móvel.²⁹

DESAFIOS E PREOCUPAÇÕES SOBRE O TEMA

Embora o *mHealth* tenha grande potencial como ferramenta de apoio à equipe de saúde, permanece ainda dúvida se essas tecnologias podem efetivamente melhorar os resultados de adesão ao tratamento e consequente controle clínico do paciente.^{30,31} Alguns aspectos que cursam desde a estrutura e desenvolvimento do aplicativo até a habilidade do usuário final em manipulá-lo podem ser fatores limitantes a um desfecho clínico favorável.³⁰

A qualidade dos aplicativos e suas finalidades variam de forma bastante significativa, sendo a maioria desenvolvida para o fornecimento de informações gerais, sem funcionalidade interativa.³² Uma revisão realizada pelo *IMS Institute – Institute for Healthcare Informatics* desenvolveu uma pontuação de classificação de funcionalidade, com uma escala que varia de 0 (baixa funcionalidade) a 100 (excelente funcionalidade), onde estabeleceu-se critérios subjacentes aos sistemas de pontuação, avaliando-se: o tipo e a quantidade de informações fornecidas; a forma como os dados são rastreados ou capturados; os processos de comunicação; e a quantidade de recursos disponíveis no dispositivo. Após avaliação de pouco mais de 16.000 aplicativos, a média de pontuação foi de apenas 40,26, indicando uma baixa qualidade da maioria dos aplicativos relacionados à saúde,³² o que sustenta o debate sobre a capacidade dos aplicativos em melhorarem

a saúde em longo prazo,³³ visto a baixa qualidade geral dos aplicativos e a falta de evidências sobre efetividade.³⁴⁻³⁷

A ausência de um órgão que realize a regulação e fiscalização desses aplicativos também é uma preocupação. Atualmente, o *Food and Drug Administration* (FDA) regula apenas os aplicativos que transformam o smartphone ou tablet em um dispositivo médico ou se destina a ser usado como acessório de um dispositivo médico regulamentado, por exemplo, monitores de glicemia e pressão arterial.³⁸ No Brasil, a Agência Nacional de Vigilância Sanitária (ANVISA) está em processo de construção de uma regulamentação para estabelecer requisitos técnicos específicos para o registro e cadastro de softwares e aplicativos para a saúde, porém até o momento não há uma regulação específica que detalhe as informações técnicas necessárias para o registro de softwares em âmbito nacional.³⁹

Uma revisão realizada sobre o desenvolvimento de aplicativos verificou que boa parte daqueles que são testados por pesquisadores não são disponibilizados comercialmente, e em contra-partida, a maioria do que está disponível em lojas como a *Apple Store* ou *Google play* não possui evidência científica que apoie sua utilização, dificultando o acesso aos profissionais de saúde e pacientes, os quais enfrentam dificuldades para identificar aqueles que são realmente eficazes.³⁴

O período de tempo para realização da pesquisa de um novo aplicativo também é um fator de grande limitação.⁴⁰ Em um estudo comum, o tempo para desenvolver o desenho do estudo pode levar de seis a 12 meses; para solicitar financiamento, aproximadamente 12 meses; para receber aprovação de um comitê de ética, seis meses; recrutar pacientes e acompanhantes, até 24 meses; analisar os dados, seis meses, e publicar os resultados, até oito meses.⁴⁰ Uma estimativa conservadora sugere que esse processo leva cerca de cinco anos, sem levar em consideração que muitas vezes a tradução da pesquisa pode levar até 17 anos.⁴⁰

Uma boa usabilidade dos aplicativos é um fator essencial para a adesão do usuário final, sendo que a simplicidade parece ser um dos recursos mais importantes na aceitação e uso de aplicativos relacionados à saúde.^{41,42} As opções devem ser claras e objetivas para evitar confusão, devendo haver um número reduzido de etapas para migrar de um recurso para o outro no aplicativo.^{41,42} Essa questão se torna ainda mais importante quando refletimos sobre a inclusão de pacientes idosos ou aqueles menos esclarecidos tecnologicamente, os quais são menos propensos a utilizar recursos de medicina digitais,⁴³ tornando a alfabetização digital em saúde um desafio adicional ao mercado, o qual exige habilidades específicas do usuário para obter desfechos clínicos favoráveis.³⁰

A complexidade para selecionar e avaliar um aplicativo ainda é uma questão desafiadora, sendo que a ausência de critérios para disponibilização desses aplicativos nas plataformas permite ao usuário realizar uma escolha não assertiva, sem base de evidência e que se torna desatualizada rapidamente.¹⁸ A avaliação da eficácia dessas ferramentas é complexa, necessitando do envolvimento dos profissionais de saúde e da regulamentação pelos órgãos de saúde, os quais dificilmente executarão essa tarefa, visto o grande volume de aplicativos disponíveis.¹⁹ Para obter sucesso com essa ferramenta no futuro é essencial que os desenvolvedores

trabalhem em conjunto com uma equipe de profissionais de saúde e pesquisadores para desenvolverem e oferecerem aplicativos baseados em evidências que efetivamente melhorem a saúde e os resultados clínicos dos pacientes.¹⁹

CONSIDERAÇÕES FINAIS

A maioria dos estudos apresentam resultados promissores em termos da capacidade da mHealth em melhorar o gerenciamento do tratamento e a adesão medicamentosa. Em resumo, as tecnologias *mHealth*, quando combinadas a um projeto de qualidade, podem produzir uma eficácia melhor que os cuidados usuais, devido à sua natureza específica de serem altamente intensivas e centradas no paciente. Porém, todas as revisões sistemáticas avaliadas^{16,21-24} apresentam ressalvas devido aos resultados não significativos, justificados em grande parte, devido ao número pequeno de participantes e o curto tempo de duração do estudo.

Como em qualquer nova tecnologia, o *mHealth* para adesão a medicamentos cardiovasculares é um trabalho em andamento. Ausência de evidências substanciais e resultados significativos não implica em ausência de eficácia. A conscientização dessa nova ferramenta está aumentando, em parte potencializada pela necessidade de novas medidas para garantir o atendimento durante a pandemia de COVID-19. No entanto, precisamos de evidências mais fortes de estudos bem projetados e implementados, com tamanhos maiores de amostra e maior duração de intervenção e acompanhamento, para confirmar o real benefício da *mHealth*.

CONFLITOS DE INTERESSE

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

REFERÊNCIAS

1. Al-Arkee S, Mason J, Lane DA, Fabritz L, Chua W, Haque MS, et al. Mobile Apps to Improve Medication Adherence in Cardiovascular Disease: Systematic Review and Meta-analysis. *J Med Internet Res*. 2021;23(5):e24190. doi:10.2196/24190. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8188316/>
2. World Health Organization. Adherence to long-term therapies: evidence for action. World Health Organization; 2003. Acessível em: http://www.who.int/chp/knowledge/publications/adherence_introduction.pdf. Acesso em 27/01/2022.
3. Miyazaki, Motoyasu, et al. "Association between medication adherence and illness perceptions in atrial fibrillation patients treated with direct oral anticoagulants: an observational cross-sectional pilot study." *PLoS One*. 2018;13(9): e0204814. <https://pubmed.ncbi.nlm.nih.gov/30265710/>
4. National Institutes of Health. Morbidity & mortality: 2012 chart book on cardiovascular, lung, and blood diseases. National Institutes of Health. 2015. Acessível em: https://www.nhlbi.nih.gov/files/docs/research/2012_ChartBook_508.pdf. Acesso em 27/01/2022.
5. Cutler RL, Fernandez – Limos, F, Frommer M, Benrimoj G, Garcia –Cardenas V. Economic impact of medication non-adherence by disease groups: a systematic review. *BMJ Popen*. 2018; 8(1): e016982. <https://pubmed.ncbi.nlm.nih.gov/29358417/>
6. McHorney CA, Spain CV. Frequency of and reasons for medication non-fulfillment and non-persistence among American adults with chronic disease in 2008. *Health Expect*. 2011;14(3):307–20.
7. Lorenzini GC, Mostaghel R, Hellström D. Drivers of pharmaceutical packaging innovation: A customer-supplier relationship case study. *J Business Research*. 2018;88(C): 363-70. https://econpapers.repec.org/article/eeeejbrese/v_3a88_3ay_3a2018_3ai_3ac_3ap_3a363-370.htm
8. World Health Organization. *mHealth: new horizons for health through mobile technologies: based on the findings of the second global survey on ehealth*. Geneva: World Health Organization. 2011.
9. Rocha TA H, et al. Mobile health: new perspectives for healthcare provision. *Epidemiologia e Serviços de Saúde*. 2016; 25(1):159- 70.
10. The Mobile Economy: 2019. London, UK: GSM Association. 2019. Acessível em: URL: <https://www.gsmainelligence.com/research/?file=b9a6e6202ee1d5f787cf6bb95d3639c5&download>. Acesso em 27/01/2022.
11. Wong M Y Z, Gunasekaran DV, Nusinovic S, Sabanayagam C, Yeo KK, Cheng C-Y, et al. Telehealth Demand Trends During the COVID-19 Pandemic in the Top 50 Most Affected Countries: Infodemiological Evaluation. *JMIR Public Health Surveill*. 2021; 7(2): e24445. doi:10.2196/24445. <https://pubmed.ncbi.nlm.nih.gov/33605883/>
12. Meirelles FS. 32ª Pesquisa Anual de Administração e Uso de Tecnologia da Informação nas Empresas. São Paulo: GVCia/EAESP/FGV. 2021. Disponível em: <https://eaesp.fgv.br/producao-intelectual/pesquisa-anual-uso-ti>. Acesso em 27/01/2022.
13. Free C, Phillips G, Watson L, Galli L, Felix L, Edwards P et al. The effectiveness of mobile-health technologies to improve health care service delivery processes: a systematic review and meta-analysis. *PLoS Med*. 2013;10(1):e1001363. <https://pubmed.ncbi.nlm.nih.gov/23458994/>
14. Tomlinson M, Rotheram-Borus MJ, Swartz L, Tsai AC. Scaling up mHealth: where is the evidence? *PLoS Med*. 2013;10(2):e1001382. <https://pubmed.ncbi.nlm.nih.gov/23424286/>
15. Bigna JJR, Noubiap JJN, Kouanfack C, Plottel CS, Koulla-Shiro S. Effect of mobile phone reminders on follow-up medical care of children exposed to or infected with HIV in Cameroon (MORE CARE): a multicentre, single-blind, factorial, randomised controlled trial. *Lancet Infect Dis*. 2014;14(7):600–8. <https://pubmed.ncbi.nlm.nih.gov/24932893/>
16. Anglada-Martinez H, Riu-Viladoms G, Martin-Conde M, Rovira-Illamola M, Sotoca-Momblona JM, Codina-Jane C. Does mHealth increase adherence to medication? Results of a systematic review. *Int J Clin Pract*. 2015;69(1):9–32. <https://pubmed.ncbi.nlm.nih.gov/25472682/>
17. Number of mHealth apps available in the Google Play Store from 1st quarter 2015 to 1st quarter 2021. In Statista - The Statistics Portal. Acessível em: <https://www.statista.com/statistics/779919/health-apps-available-google-play-worldwide/> Acesso em 27/01/2022.
18. Keusch F, Wenz A, Conrad F. Do you have your smartphone with you? Behavioral barriers for measuring everyday activities with smartphone sensors. *Computers in Human Behavior*. 2022; 127: 107054. <https://www.sciencedirect.com/science/article/abs/pii/S0747563221003770>
19. Neubeck L, Lowres N, Benjamin EJ, Freedman SB, Coorey G, Redfern J. The mobile revolution—using smartphone apps to prevent cardiovascular disease. *Nat Rev Cardiol*. 2015;12(6): 350-60. <https://pubmed.ncbi.nlm.nih.gov/25801714/>
20. Cameron JD, Ramaprasad A, Syn T. An ontology of and roadmap for mHealth research. *Int J Med Inform*. 2017;100:16–25. <https://pubmed.ncbi.nlm.nih.gov/28241934/>
21. Gandapur Y, Kianoush S, Kelli HM, Misra S, Urrea B, Blaha MJ, et al. The role of mHealth for improving medication adherence in patients with cardiovascular disease: a systematic review. *Eur Heart J Qual Care Clin Outcomes*. 2016;2(4):237–44. <https://pubmed.ncbi.nlm.nih.gov/29474713/>
22. Hamine S, Gerth-Guyette E, Faulx D, Green BB, Ginsburg AS.

- Impact of mHealth chronic disease management on treatment adherence and patient outcomes: a systematic review. *J Med Internet Res.* 2015;17(2):e52. <https://pubmed.ncbi.nlm.nih.gov/25803266/>
23. Gandhi S, Chen S, Hong L, Sun K, Gong E, Li C, et al. Effect of mobile health interventions on the secondary prevention of cardiovascular disease: systematic review and meta-analysis. *Can J Cardiol.* 2017;33(2):219–31. <https://pubmed.ncbi.nlm.nih.gov/27956043/>
 24. Hamine S, Gerth-Guyette E, Faulx D, Green BB, Ginsburg AS. Impact of mHealth chronic disease management on treatment adherence and patient outcomes: a systematic review. *J Med Internet Res.* 2015;17(2):e52.
 25. Park LG, Howie-Esquivel J, Chung ML, Dracup K. A text messaging intervention to promote medication adherence for patients with coronary heart disease: a randomized controlled trial. *Patient Educ Couns.* 2014;94(2):261–8. <https://pubmed.ncbi.nlm.nih.gov/24321403/>
 26. Quilici J, Fugon L, Beguin S, Morange PE, Bonnet J-L, Alessi M-C, et al. Effect of motivational mobile phone short message service on aspirin adherence after coronary stenting for acute coronary syndrome. *Int J Cardiol.* 2013;168(1):568–9. <https://pubmed.ncbi.nlm.nih.gov/23462636/>
 27. Fang R, Li X. Electronic messaging support service programs improve adherence to lipid-lowering therapy among outpatients with coronary artery disease: an exploratory randomised control study. *J Clin Nurs.* 2016;25(5-6):664–71. <https://pubmed.ncbi.nlm.nih.gov/26522838/>
 28. Buis L, Hirzel L, Dawood RM, Dawood KL, Nichols LP, Artinian NT, et al. Text messaging to improve hypertension medication adherence in African Americans from primary care and emergency department settings: results from two randomized feasibility studies. *JMIR Mhealth Uhealth.* 2017;5(2):e9. <https://pubmed.ncbi.nlm.nih.gov/28148474/>
 29. Finitzis DJ, Pellowski JA, Johnson BT. Text message intervention designs to promote adherence to antiretroviral therapy (ART): a meta-analysis of randomized controlled trials. *PLoS One.* 2014;9(2):e88166. <https://pubmed.ncbi.nlm.nih.gov/24505411/>
 30. Smith B, Magnani JW. New technologies, new disparities: The intersection of electronic health and digital health literacy. *Int J Cardiol.* 2019; 292: 280–2. <https://pubmed.ncbi.nlm.nih.gov/31171391/>
 31. Tomlinson M, Rotheram-Borus MJ, Swartz L, Tsai AC. Scaling up mHealth: where is the evidence? *PLoS Med.* 2013;10(2):e1001382.
 32. IMS Institute for Healthcare Informatics. *Patient Apps for Improved Healthcare: From Novelty to Mainstream*, 2013. Disponível em: http://moodle.univille2.fr/pluginfile.php/215345/mod_resource/content/0/IIHI_Patient_Apps_Report.pdf. Acesso em: 27/01/2022.
 33. Buijink AWG, Visser B J Marshall L. Medical apps for smartphones: lack of evidence undermines quality and safety. *Evid. Based Med.* 2013;18(3): 90–2. <https://pubmed.ncbi.nlm.nih.gov/22923708/>
 34. de la Vega R, Miró J. mHealth: a strategic field without a solid scientific soul: a systematic review of pain-related apps. *PLoS One* 2014;9(7): e101312.
 35. Dubey D, Amritphale A, Sawhney A, Amritphale N, Dubey P, Pandey A. Smart phone applications as a source of information on stroke. *J. Stroke.* 2014;16(2), 86–90. .
 36. Abrams LC, Padmanabhan N, Thaweethai L, Phillips T. iPhone apps for smoking cessation: a content analysis. *Am J Prev Med.* 2011;40(3): 279–85. <https://pubmed.ncbi.nlm.nih.gov/21335258/>
 37. Breton ER, Fuemmeler BF, Abrams LC. Weight loss—there is an app for that! But does it adhere to evidence-informed practices? *Transl Behav Med.* 2011;1(4): 523–9. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3717669/>
 38. FDA. *Mobile Medical Applications* [online]. Acessível em: <http://www.fda.gov/downloads/MedicalDevices/DeviceRegulationandGuidance/GuidanceDocuments/UCM263366.pdf> (2015).
 39. Anvisa. *Anvisa discute registro de aplicativos usados em saúde*. 2018 Disponível em: http://portal.anvisa.gov.br/noticias/asset_publisher/FXrx9qY7FbU/content/anvisa-discute-registro-de-aplicativos-usados-em-saude/219201/pop_up?_101_INSTANCE_FXrx9qY7FbU_viewMode=print&_101_INSTANCE_FXrx9qY7FbU_languageld=pt_BR. Acesso em 26/01/2022.
 40. Morris ZS, WoodingS, Grant J. The answer is 17 years, what is the question: understanding time lags in translational research. *J R Soc Med.* 2011;104(12): 510–20. <https://pubmed.ncbi.nlm.nih.gov/22179294/>
 41. Gay V, Leijdekkers P. The good, the bad and the ugly about social networks for health apps. . In 2011 IFIP 9th International Conference on Embedded and Ubiquitous Computing (EUC). IEEE. 2011;463–68.. <https://dl.acm.org/doi/10.1109/EUC.2011.69>
 42. Zhang C, Zhang X, Halstead-Nussloch R. Assessment metrics, challenges and strategies for mobile health apps. *Issues in Information Systems.* 2014; 15:59–66. <https://www.semanticscholar.org/paper/Assessment-Metrics%2C-Challenges%2C-and-Strategies-for-Zhang-Zhang/b2104aa8de5ee2a5deaef7931ae6ae58c808bebd>
 43. Kvedar JC, Fogel AL, Elenko E, Zohar D. Digital medicine's march on chronic disease. *Nat Biotechnol.* 2016;34(3):239–46. <https://pubmed.ncbi.nlm.nih.gov/26963544/>

INTELIGÊNCIA ARTIFICIAL NA AVALIAÇÃO DO CONSUMO ALIMENTAR: AVANÇOS NA ANÁLISE DA DIETA E PREDIÇÃO DE DESFECHOS CARDIOVASCULARES

ARTIFICIAL INTELLIGENCE IN DIETARY INTAKE ASSESSMENT: ADVANCES IN DIET ANALYSIS AND PREDICTION OF CARDIOVASCULAR OUTCOMES



Clique para acessar
o Podcast

Vanderlei Carneiro Silva¹
Dirce Maria Marchioni²
Tânia Aparecida de Araujo^{3,4}
Angélica Castilho Alonso⁵
Isabela Martins Benseñor¹

1. Universidade de São Paulo. Hospital Universitário. Centro de Pesquisa Clínica e Epidemiológica. São Paulo, SP, Brasil.

2. Universidade de São Paulo. Faculdade de Saúde Pública. Departamento de Nutrição. São Paulo, SP, Brasil.

3. Fundação Oswaldo Cruz Amazônia. Instituto Leônidas e Maria Deane. Manaus, AM, Brasil.

4. Centro Universitário de Pato de Minas – UNIPAM. Patos de Minas, MG, Brasil.

5. Universidade de São Paulo. Hospital das Clínicas. Instituto de Ortopedia e Traumatologia. Laboratório do Estudo do Movimento. São Paulo, SP, Brasil.

Correspondência:
Vanderlei Carneiro Silva.
vnd.cs@hotmail.com

RESUMO

A disponibilidade de grandes bancos de dados para análise associada ao desenvolvimento da capacidade de processamento, visualização e integração de diferentes fontes de informação em saúde têm impulsionado a aplicação de modelos baseados em Inteligência Artificial (IA) e no Aprendizado de Máquina para avaliação do consumo alimentar. O presente estudo tem como objetivo apresentar os avanços da IA na avaliação do consumo alimentar e predição de desfechos cardiovasculares. Foi realizada uma revisão da literatura para identificar os avanços e apresentar as perspectivas no campo da epidemiologia nutricional com o uso de algoritmos e inovações tecnológicas. Nos últimos anos, a aplicação da IA em inquéritos sobre o consumo alimentar apresentou resultados promissores na análise de padrões alimentares associados à obesidade e o desenvolvimento de doenças crônicas como diabetes, câncer e doenças cardiovasculares. Inovações tecnológicas na aplicação de métodos já estabelecidos para coleta de dados da dieta tais como recordatórios de 24 horas e questionários de frequência alimentar, têm permitido a construção de modelos preditivos para segmentar indivíduos com características demográficas e sociais similares, identificar relações no consumo de alimentos e grupos de alimentos, além de prever os padrões de risco populacional de desenvolvimento de doenças. Os avanços nesta área podem subsidiar a tomada de decisão clínica com desenvolvimento de ações personalizadas em saúde.

Descritores: Inteligência Artificial; Aprendizado de Máquina; Dieta; Epidemiologia Nutricional; Nutrição Personalizada.

ABSTRACT

The availability of large databases for analysis, combined with the development of processing capacity, visualization, and integration of different sources of health information, have driven the application of models based on artificial intelligence (AI) and machine learning to evaluate food consumption. The present study aims to present AI advances in the assessment of food consumption and the prediction of cardiovascular outcomes. A literature review was conducted to identify advances and current perspectives in the field of nutritional epidemiology using algorithms and technological innovations. In recent years, the application of AI to food consumption surveys has shown promising results in the analysis of dietary patterns associated with obesity and the development of chronic diseases such as diabetes, cancer, and cardiovascular diseases. Technological innovations in the application of already established methods for collecting dietary data, such as 24-hour recalls and food frequency questionnaires, have allowed the construction of predictive models to segment individuals with similar demographic and social characteristics, identify relationships between food consumption and food groups, in addition to predicting populational disease development risk patterns. Advances in this area can support clinical decision-making through the development of personalized healthcare actions.

Keywords: Artificial Intelligence; Machine Learning; Diet; Nutritional Epidemiology; Personalised Nutrition.

INTRODUÇÃO

As mudanças que ocorreram nos padrões alimentares da população brasileira, a exemplo do que também se observou em outros países, constituem desafios para os sistemas de saúde pública.¹ O excesso de peso e as doenças crônicas não transmissíveis têm grande impacto sobre o perfil de morbidade e mortalidade na sociedade. Prevalências elevadas dessas doenças estão associadas com transformações observadas em todas as faixas etárias e status socioeconômico. Incluem mudanças, em grande parte combinadas, no estilo de vida, dieta baseada em produtos com alto grau de processamento, em detrimento de alimentos *in natura* e minimamente processados, excessos no consumo de bebidas alcoólicas, tabagismo, pior qualidade do sono e inatividade física.^{2,3} Por sua vez, essas mudanças irão gerar demanda por ações preventivas e de promoção da saúde.⁴

A avaliação do consumo alimentar é uma área de estudo da epidemiologia nutricional e permite analisar, por meio da aplicação dos métodos de coleta, informações sobre qualidade da dieta, aspectos que envolvem seleção, preparo e consumo dos alimentos, frequência e quantidades das porções consumidas, preferências, restrições, intolerâncias, entre outros.⁵ Os principais métodos para coleta de dados, parte do processo relacionado com a avaliação da dieta, incluem a história alimentar, diário ou registro alimentar, recordatório de 24 horas, *screeners* e questionário de frequência alimentar.⁶ A escolha do método ou combinação entre eles, além da avaliação com medidas repetidas, depende do objetivo da análise. Pode estar relacionada com o consumo de alimentos, nutrientes, grupos específicos de alimentos e nutrientes ou avaliação da dieta considerando espaço de tempo previamente definido. Entretanto, quando se deseja estudar a dieta como fator de exposição para desfechos em saúde, como no caso das doenças cardiovasculares, usualmente o que se busca é uma estimativa verdadeira da dieta habitual.^{7,8}

Por um outro lado, independentemente do método de avaliação do consumo alimentar todos eles apresentam vantagens e desvantagens.⁹ Entre os disponíveis, eles fornecem uma estimativa e não mensuram, necessariamente, a ingestão real dos indivíduos. Assim, para que a avaliação da dieta ocorra adequadamente é fundamental que o relato obtido seja acompanhado de detalhes, tanto quanto possível, sobre as refeições e comportamentos relacionados à alimentação e a comensalidade. Recordar e descrever a própria dieta é uma habilidade que tende a variar entre os indivíduos, especialmente nos extremos de idade. Deste modo, métodos estatísticos têm sido desenvolvidos para reduzir a variabilidade nos dados e estimar a ingestão habitual.¹⁰⁻¹²

A evolução da tecnologia tem proporcionado o desenvolvimento de ferramentas analíticas em diversas áreas, incluído a nutrição.¹³ A Inteligência Artificial revolucionou as relações sociais e culturais globalmente, muito além do uso exclusivo para pesquisa.¹⁴ Com isso, a epidemiologia nutricional encontrou novos parceiros: os algoritmos. A análise de dados orientada pelo Aprendizado de Máquina (AM) é capaz de modelar e aprender sobre padrões complexos, tais como a dieta.^{15,16} O uso de dispositivos móveis com sistemas inteligentes abre caminhos na avaliação do consumo alimentar por meio do reconhecimento de imagens contendo alimentos, capacidade de processar dados em tempo real, menor inclusão de viés por não depender exclusivamente

da memória do entrevistado, suporte a tomada de decisão e orientação do cuidado em saúde.¹⁷⁻¹⁹ O presente estudo tem como objetivo apresentar os avanços na avaliação do consumo alimentar e predição de desfechos cardiovasculares com a utilização de inteligência artificial.

ALGORITMOS E O PROCESSO DE APRENDIZAGEM

Há muito tempo a inteligência humana se constitui objeto de estudo que, por sua natureza complexa, demanda conhecimentos multidisciplinares. O desejo de reproduzir nas máquinas a habilidade de aprender e resolver problemas, possui aplicação em muitas áreas.²⁰ Análises preditivas têm alcançado um novo patamar com os algoritmos, os grandes bancos de dados e uma maior capacidade de processamento de informações pelos equipamentos disponíveis atualmente. Inteligência Artificial tem como objetivo simular a inteligência humana em sistemas artificiais para que possam executar tarefas em eficiência equivalente ou superior ao homem. Já o AM trata-se de um subcampo da IA que combina conhecimentos das ciências exatas, informática, linguagem de programação de computadores, educação e neurociência.²¹ O AM estuda a construção de modelos baseados no uso de algoritmos a partir de instâncias de dados que representam um problema da vida real. Em outras palavras, trata-se da análise de dados que permite encontrar funções matemáticas que explicam a relação entre variáveis e deem, ao computador, a habilidade de aprender e fazer previsões.²²

O aprendizado realizado com as máquinas busca simular a forma como os seres humanos aprendem. Um conjunto de características é fornecido ao algoritmo para que ele aprenda sobre determinado problema que deve ser resolvido. Uma vez que o modelo é treinado, espera-se generalizar em dados desconhecidos.²¹ Assim, não basta a memorização por parte do sistema artificial, aprender envolve a capacidade de se transformar, adaptar e evoluir. O treinamento de um modelo ocorre por meio de processos interativos que encontram padrões e, em alguns casos, relacionamentos ocultos nos dados. Além disso, é possível ajustar as análises, customizar hiperparâmetros, atribuir pesos para os acertos e penalizações aos erros para que a taxa de aprendizado aumente e o modelo apresente um melhor desempenho.²²

Entre as classificações existentes, o aprendizado de máquina pode ser dividido em três tipos principais. O primeiro é o aprendizado supervisionado, o qual caracteriza-se pelo treinamento do modelo com o fornecimento das variáveis de saída (desfecho) e dos preditores. O segundo, denominado de não supervisionado, apenas os atributos são fornecidos. Neste caso, o próprio algoritmo se encarrega de encontrar funções e padrões nos dados, o que permite modelar desfechos cuja variável de saída não é conhecida previamente pelo pesquisador ou quando não há uma variável de classificação.²³ Já o terceiro tipo, aprendizado por reforço, envolve a tomada de decisão com base na interação da máquina com um agente externo, fornecendo *feedback* como premiações e penalizações. Neste último caso, o sistema é guiado e navega pelo espaço de possibilidades para resolução do problema, aumentando a sua aprendizagem, tal como ocorre quando computadores, ao interagir com um jogador real, aprendem ações que levam a ganhar uma partida.²⁴

A avaliação da performance do modelo ocorre com a divisão dos dados em subconjuntos de treino e teste. Apesar de os valores não serem fixos, usualmente 70% dos dados são utilizados para treinamento e 30% para testes. Nos dados de teste as previsões são comparadas com os valores reais ou previamente disponíveis, mas que não foram utilizados na etapa de treinamento do modelo. Assim, com base nos erros e acertos são calculadas as métricas como acurácia, precisão, sensibilidade, especificidade, valores preditivos positivo e negativo, taxas de erro absoluto e médio.²⁵ Essas informações permitem a avaliação de um modelo isoladamente ou comparação entre vários deles, por exemplo, quando implementados com diferentes algoritmos. A Tabela 1 apresenta as principais métricas de avaliação utilizadas para avaliação da performance de modelos de classificação.

O poder preditivo e o potencial de uso dessa tecnologia aumentaram muito nos últimos anos. A maioria das técnicas

Tabela 1. Matriz de Confusão.

Predição	Referência	
	Evento	Não Evento
Evento	A	B
Não Evento	C	D

Fórmulas utilizadas conforme descrição:

Sensibilidade = $A/(A+C)$

Especificidade = $D/(B+D)$

Prevalência = $(A+C) / (A+B+C+D)$

Valor Preditivo Positivo (VPP) = $(\text{sensibilidade} * \text{prevalência}) / ((\text{sensibilidade} * \text{prevalência}) + ((1 - \text{especificidade}) * (1 - \text{prevalência})))$

Valor Preditivo Negativo (VPN) = $(\text{especificidade} * (1 - \text{prevalência})) / (((1 - \text{sensibilidade}) * \text{prevalência}) + (\text{especificidade} * (1 - \text{prevalência})))$

Taxa de Detecção = $A/(A+B+C+D)$

Prevalência de Detecção = $(A+B)/(A+B+C+D)$

Acurácia Balanceada = $(\text{sensibilidade} + \text{especificidade}) / 2$

Precisão = $A/(A+B)$

Recall = $A/(A+C)$

já existem há várias décadas, no entanto com a expansão do volume de dados disponíveis para análise, equipamentos mais eficientes para armazenamento e processamento ágil dos dados, os algoritmos têm apresentado desempenhos elevados mesmo em modelagens complexas, com baixo custo e em diversas áreas.²⁶ Assim como seres humanos e também os animais, que recorrem as suas experiências quando são expostos a situações que exigem tomada de decisão, os modelos baseados no aprendizado de máquina realizam previsões nos dados desconhecidos considerando o treinamento que foi realizado previamente. Após a construção do modelo, realizar inferência em dados desconhecidos é a ação de generalização que se busca.²²

Entre as muitas aplicações com IA já existentes, citam-se: análise de sentimento baseada em texto, reconhecimento de voz e imagem, treinamento de carros autônomos, detecção de fraudes em transações financeiras e desenvolvimento de sistemas de recomendação.^{21,25} Na área da saúde, o uso se faz no suporte clínico e diagnóstico, assistência em saúde personalizada, análise de dados de consumo alimentar, reconhecimento de imagens contendo alimentos, construção de sistemas de recomendação, gestão de condições clínicas, promoção da saúde, aconselhamento e prevenção de doenças.^{14,27,28}

A Figura 1 apresenta a modelagem de dados para predição do risco de doenças cardiovasculares. Após definidos os objetivos da análise, um conjunto de preditores (variáveis) é coletado e fornecido para o algoritmo que irá construir o modelo preditivo. Ao final do processo, o modelo fornece as previsões sobre presença ou não do risco de doença cardiovascular. Além disso, ajustes podem ser adotados a fim de melhorar o desempenho do modelo, incluindo nova etapa de coleta de dados para reiniciar o processo ou mesmo a adoção de medidas de intervenção para reduzir o risco da doença ou início do tratamento, quando necessário.

INOVAÇÕES TECNOLÓGICAS NA AVALIAÇÃO DA DIETA

A avaliação da dieta permite gerar conhecimento sobre a alimentação, identificar os determinantes e tendências no consumo de indivíduos e grupos. Desta forma é possível planejar




Figura 1. Modelagem preditiva para risco de doença cardiovascular.

ações, orientar assistência e serviços de saúde, implementar políticas públicas, avaliar comportamentos de risco entre indivíduos para o desenvolvimento de doenças associadas com o excesso ou deficiências nutricionais.²⁹ Com o apoio da tecnologia é possível automatizar algumas etapas do processo de análise de dados, com redução do tempo e recursos necessários, especialmente em amostras muito grandes.

Especialistas em nutrição, ciências da computação e análise de dados têm atuado em conjunto com foco no desenvolvimento e validação de sistemas de suporte em inquéritos alimentares.³⁰ Illner et al.,³¹ em revisão da literatura descreveram que os principais grupos de inovações tecnológicas utilizados em estudos epidemiológicos compreendem assistentes pessoais digitais (PDA), telefone móvel, plataformas baseadas em computador e na web, gravadores de voz e dispositivos com câmera embutida, sensores e scanner. Como vantagens dessas inovações, há redução do tempo e trabalho para coleta de dados, especialmente em grandes grupos e populações dispersas geograficamente, além de melhorar a qualidade do relato por depender menos da memória do entrevistado.

Timon et al.,³² acrescentam que a tecnologia oferece soluções para muitas das limitações das metodologias tradicionais na avaliação da dieta; menor custo, maior taxa de participação e acurácia na coleta de dados, enquanto Thompson et al.,³³ afirmam que participantes preferem métodos autoaplicáveis que os administrados por um entrevistador. Desta forma, a coleta, tabulação e análise de dados relacionados a alimentação humana ganharam reforço com a informática, tanto em nível individual como coletivo.

Alguns softwares disponíveis no mercado já há alguns anos permitem avaliar o consumo de alimentos e preparações com o auxílio de porções de referência e medidas caseiras a partir de arquivos de imagens de apoio, como usualmente são relatadas pelos pacientes.³⁴⁻³⁶ Essas ferramentas otimizam o processo de análise da dieta, bem como os cálculos de estimativa da ingestão de nutrientes com base em tabelas de composição de alimentos. A complexidade dessa atividade se ampliou com a oferta de uma diversidade produtos industrializados com redução de calorias, gorduras, açúcares, glúten, lactose e acréscimo de substâncias para o seu enriquecimento. Uma funcionalidade implementada em alguns desses softwares é a possibilidade de realizar cálculos em preparações com diferentes opções de receitas.³⁷ A relevância no uso dessas ferramentas não é apenas cálculo mais ágil de todo esse volume de dados, mas também redução de erros pelo entrevistador e entre os entrevistadores com a padronização da coleta. No entanto, é necessário que os aplicativos disponham de bancos de dados válidos com tabelas de composição de alimentos atualizadas.

Um outro tipo de inovação são as plataformas interativas para usuários de telefone móvel, com lembretes e sugestões para alimentação saudável, em alguns casos, associada à prática de atividade física.³⁸ Considerando o uso atual de smartphones, a cultura de registrar e compartilhar todos os momentos, incluindo as refeições, aplicativos em dispositivos móveis podem coletar um grande volume de dados, independente da memória do entrevistado, realizar segmentação, predição dos alimentos consumidos, estimar quantidade e o valor nutricional da refeição, além de dados

de localização geográfica para avaliação do consumo de alimentos saudáveis considerando oferta desses alimentos em um perímetro específico de análise.^{18,19}

ANÁLISE PREDITIVA NA AVALIAÇÃO DA DIETA

A ciência da nutrição avançou no entendimento de que a alimentação é mais que a ingestão de nutrientes ou alimentos isoladamente. A dieta é influenciada por fatores biológicos, sociais, econômicos, demográficos e culturais.³⁹ A escolha dos alimentos que compõem as refeições e que se fazem presentes à mesa é complexa e, portanto, a avaliação do consumo alimentar demanda abordagens holísticas e complementares. Modelos baseados em inteligência artificial e na utilização de algoritmos para análise de dados com o aprendizado de máquina podem adicionar informações importantes no entendimento da dieta e dos fatores que a influenciam sem, contudo, dispensar métodos e técnicas já utilizados na epidemiologia nutricional.¹⁴

Alguns trabalhos já publicados descrevem metodologias de análise da dieta com a utilização de aprendizagem supervisionada, bem como as vantagens de sua utilização. Para Giabbanelli and Adams,⁴⁰ muitos métodos de avaliação da dieta buscam estimar a ingestão de alimentos e nutrientes. Porém, se a intenção é apenas determinar se os participantes alcançam recomendações dietéticas, algumas avaliações podem coletar dados redundantes. Os autores exploraram o número de alimentos que é capaz de prever alcance de recomendações dietéticas como frutas e vegetais, sódio, gorduras, gorduras saturadas e açúcares livres. Após analisar os dados de 4.156 indivíduos participantes do *UK National Diet and Nutrition Survey* (NDNS, 2008-12) com árvores de decisão, informação sobre o consumo de 113 dos 3.911 (3%) alimentos analisados, adicionados de idade e sexo pode prever com 72-73% de acurácia o alcance das recomendações dietéticas.

Hearty and Gibney¹⁶ analisaram um banco de dados de consumo de alimentos do *North-South Ireland Food Consumption Survey*. Redes Neurais Artificiais e Árvores de Decisão foram utilizados para prever quintis de um Índice de Qualidade da Dieta (*Healthy Eating Index* – HEI) baseados em combinações de alimentos consumidos no café da manhã e refeições principais de 1.379 adultos. Ambos os algoritmos foram bem-sucedidos em prever aspectos de qualidade da dieta do conjunto de dados analisado.

A performance de um método para identificar padrões dietéticos de homens e mulheres adultos que participaram do *Framingham Nutrition Studies* foi avaliada no trabalho de Pencina et al.,⁴¹ Funções discriminantes de Fischer foram utilizadas para classificar os participantes em um dos cinco padrões alimentares derivados para cada sexo. Os autores concluíram que o método é válido e confiável para identificar os padrões com acurácia de 80% e Kappa estatístico superior a 0.70. Além disso, que a abordagem utilizada pode guiar o desenvolvimento de índices de qualidade da dieta.

No Brasil, Silva et al.,⁴² utilizaram aprendizado de máquina para prever padrões alimentares de 12.667 servidores públicos de ambos os sexos participantes do Estudo Longitudinal de Saúde do Adulto (ELSA-Brasil). Em um grande estudo transversal, dados de consumo alimentar foram

analisados a partir da aplicação de um Questionário de Frequência Alimentar semiquantitativo. O objetivo do estudo foi prever padrões alimentares a partir de um conjunto de variáveis sociodemográficas e clínicas. Dois clusters foram identificados. O Padrão Prudente foi caracterizado por maior consumo de frutas, vegetais, cereais integrais, carnes brancas, leite e derivados com teor reduzido de gorduras. O Padrão Ocidental foi caracterizado por maior consumo de cereais refinados, feijões e outras leguminosas, tubérculos, massas, carnes vermelhas e processadas, leite e derivados com alto teor de gorduras, bebidas adoçadas. Entre os preditores, idade, sexo, renda, nível de escolaridade e atividade física foram os mais importantes na predição da dieta. A acurácia dos modelos variou entre 69 e 72%.

INTELIGÊNCIA ARTIFICIAL, DIETA E PREDIÇÃO DE DESFECHOS CARDIOVASCULARES

A Figura 2 apresenta a aplicação de um modelo teórico de árvore de decisão para predição do risco de doença cardiovascular. Esse algoritmo identifica, por meio da escolha de atributos que melhor divide o conjunto de dados, aqueles com maior influência sobre o desfecho em análise. No exemplo, retângulos representam os atributos, com o topo da árvore identificando a variável mais importante, seguida das demais, até que uma decisão ocorra nas folhas da árvore, os círculos. A ilustração gerada pelo algoritmo não implica em um fator causal de uma variável sobre o risco cardiovascular, porém de um conjunto de variáveis que foram apresentadas em nível de importância para prever o desfecho. Portanto, conhecimento em bioestatística, desenho de estudos e epidemiologia são complementares à interpretação dos resultados.

O exemplo de predição citado acima pode ser aplicado a uma série de outros algoritmos⁴³ com uma sequência de etapas de pré-processamento, análise de dados e, obviamente, de visualizações gráficas que variam de acordo com a fundamentação teórica de cada um deles. A seguir nós vamos apresentar alguns dos principais estudos que utilizaram diferentes algoritmos baseados na combinação de dados clínicos e de consumo alimentar para predição do risco de doença cardiovascular.

Um dos primeiros estudos que utilizou o estado da arte de algoritmos de classificação foi o de Kastorini et al.,⁴⁴ que compararam padrões dietéticos a priori e a posteriori na predição de Síndrome Coronariana e Acidente Vascular Encefálico. Os autores analisaram os dados de 1.000 participantes (500 casos vs. 500 controles), de ambos os sexos, provenientes de três hospitais na Grécia (*University General Hospital of Ioannina*, "Hellenic Red Cross" *Korgialeneio-Benakeio Hospital, Athens* e *Alexandra Hospital, Athens*). Os padrões a priori foram derivados do MedDietScore validado, enquanto o a posteriori foi extraído por análise de componentes principais. As duas abordagens foram modeladas para a predição dos desfechos baseados na utilização de diferentes algoritmos; *Multiple Logistic Regression (MLR)*, *Naïve Bayes*, *Decision Trees*, *Repeated Incremental Pruning to Produce Error Reduction (RIPPER)*, *Artificial Neural Networks* e *Support Vector Machines*, os quais apresentaram acurácia equivalente.

Basnet et al.,⁴⁵ em estudo do tipo caso controle avaliaram a importância relativa da ingestão dietética de nutrientes na ocorrência de doença arterial coronariana. Neste estudo nepalês com 612 participantes (*Shahid Gangalal National Heart Center*), a ingestão dietética foi avaliada a partir de um questionário de frequência alimentar semiquantitativo, adaptado para a população do estudo. As análises preditivas foram realizadas com modelos baseados em *Random Forest (RF)* e identificaram que os ácidos graxos saturados, vitamina A, gorduras totais, beta caroteno e colesterol foram os nutrientes de maior importância relativa associados com os desfechos (acurácia 84% e *Area Under the Curve* 91%). Conforme descrito pelos autores, RF consiste em um modelo que atua como um *ensemble*. Neste caso, muitas árvores de decisão são correlacionadas por reamostragem dos dados o que permite a construção de um classificador final com excelente desempenho. Cada árvore fornece uma classificação e a floresta seleciona a classificação com a maioria dos votos. Esse tipo de modelo é comum para tarefas de predição na área médica.

Em um outro estudo Biesbroek et al.,⁴⁶ identificaram padrões dietéticos relacionados a fatores de risco cardiovascular com *Reduced Rank Regression (RRR)* e *Random Forest*. Questionários de Frequência Alimentar foram utilizados para estimar a ingestão de 34.644 participantes do *European Prospective Investigation into Cancer-Netherlands (EPIC)*.

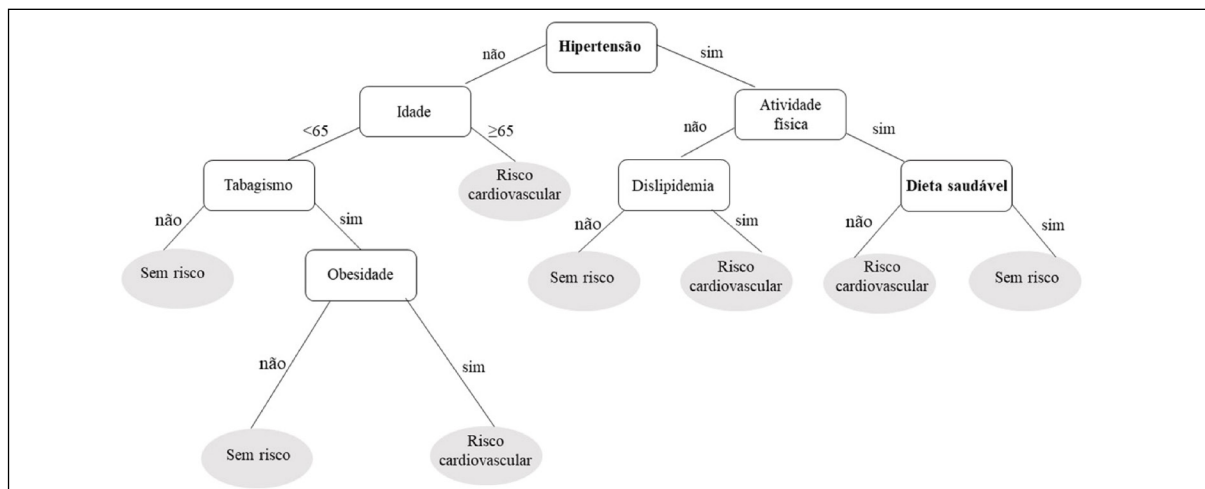


Figura 2. Modelo teórico da aplicação de um algoritmo de árvore de decisão para predição do risco de doença cardiovascular.

Métodos híbridos foram utilizados para incorporar informação sobre nutrientes ou fatores biológicos e extrair os padrões relevantes para doença cardiovascular. Neste estudo, tanto o RRR como RF resultaram em pequenas diferenças nos grupos de alimentos analisados contribuindo para extração de padrões similares que mostraram, no geral, associações mais fortes que os padrões derivados por *principal component analysis* (PCA) e *k-means cluster analysis* (KCA).

Panaretos et al.,¹⁵ compararam regressão linear e métodos baseados em aprendizado de máquina (*k-nearest-neighbor's* e *random-forests*) na associação entre padrões alimentares e o risco cardiometabólico em 10 anos de acompanhamento no ATTICA study, um estudo prospectivo baseado na população

conduzido em áreas metropolitanas de Atenas, Grécia (2002-2012). A Teoria de Resposta ao Item foi aplicada para desenvolver uma métrica combinada de risco (*Cardiometaabolic Health Score*), que incorporou a incidência de doença cardiovascular, diabetes, hipertensão e hipercolesterolemia. Os métodos foram aplicados para avaliar a saúde dos participantes baseados na informação da dieta. Os autores concluíram que os métodos de aprendizado de máquina, comparados à regressão linear, apresentaram maiores acurácias na avaliação do risco relacionado a doença (38 vs. 6% de acurácia).

A Tabela 2 apresenta os algoritmos utilizados em epidemiologia nutricional, características principais, vantagens e desvantagens.

Tabela 2. Algoritmos utilizados na epidemiologia nutricional.

Algoritmos	Características	Vantagens	Desvantagens
K-means	Método de cluster. Faz parte do conjunto de técnicas de aprendizagem não supervisionada.	Identifica padrões automaticamente, permite segmentar os indivíduos.	Sensível a escala nos dados. Desafio é lidar com o número de clusters vs. variabilidade dos dados na amostra.
	Um dos algoritmos mais populares. Agrupa indivíduos por similaridade. Objetivo é encontrar padrões.	Rápido e menos subjetivo que os algoritmos aglomerativos.	Necessário atribuir significado aos grupos identificados.
DT	Ilustração gráfica remete uma árvore de cabeça para baixo. Apresenta boa capacidade preditiva.	Utilizadas como ferramentas de apoio a decisão.	Sujeita a <i>overfitting</i>
	Útil em predições de classificação e regressão.	Ilustração gerada é de fácil visualização e entendimento.	A árvore pode crescer muito, sendo necessário empregar técnicas de poda.
SVM	Máquinas de Vetores de Suporte traçam uma linha de separação entre os dados que é chamada de hiperplano.	Lida com dados não linearmente separáveis, desconsidera <i>outliers</i> .	Abstrato, pouco poder de interpretação. Algoritmo atua como uma caixa preta.
	Pontos de dados são mapeados de modo que os exemplos de cada categoria são divididos por um espaço claro e bem definido.	Constrói excelentes classificadores em conjuntos de dados complexos e multidimensionais.	
NB	Baseado no teorema de <i>Bayes</i> .	Classificador probabilístico simples, útil em grandes bases de dados e pode apresentar resultados superiores a outras técnicas mais sofisticadas.	A classificação é chamada de ingênua.
	Calcula a probabilidade de uma amostra desconhecida pertencer a uma classe possível.	Utilizado para previsões multiclases, classificação de textos, organização automática de <i>e-mails</i> , filtragem de <i>spam</i> , identificação de páginas com conteúdo adulto, análise de sentimento, detecção de expressões multipalavras, previsões em tempo real, sistema de recomendação.	Considera que o efeito de um atributo na ocorrência de uma classe é independente da presença ou ausência de qualquer outro atributo.
Knn	A classificação de uma entrada desconhecida é realizada com base no rótulo dos exemplos de treinamento dos vizinhos mais próximos no espaço de características.	Algoritmo de fácil compreensão e implementação, sendo a base para métodos mais avançados e pode ser utilizado em etapas iniciais de modelagem de problemas complexos.	Sensível a escala nos dados. Pode ser lento em grandes conjuntos de dados.
		É capaz de gerar rapidamente o caminho mais curto entre dois pontos.	
RF	Combina diferentes modelos. Cada árvore é treinada com uma amostra de dados aleatória.	Mensura com facilidade a importância relativa de um dado atributo na sua escolha entre as diversas árvores construídas.	Árvores são correlacionadas.
	Baseado na estratégia <i>ensemble</i> .	Alta performance.	Requer maior capacidade computacional.

Legenda: DT, *decision trees*; SVM, *support vector machines*; NB, *naïve bayes*; RF, *random forest*.

PERSPECTIVAS NA AVALIAÇÃO DO CONSUMO ALIMENTAR

O presente estudo abordou os avanços na aplicação de Inteligência Artificial na avaliação do consumo alimentar. Os resultados dos estudos já desenvolvidos são promissores e demonstram que essa área deve receber ainda mais atenção nos próximos anos. As inovações tecnológicas e o uso dos algoritmos podem se constituir como abordagens complementares às metodologias já estabelecidas para o estudo e predição de desfechos em saúde, além de subsidiar a tomada de decisão e o desenvolvimento de ações personalizadas.

Apesar da recente popularização no campo da saúde e de suas contribuições na epidemiologia nutricional, o uso de sistemas inteligentes requer investimentos para a sua adoção no contexto de diferentes realidades no Brasil. São necessários recursos, infraestrutura, qualificação de equipes multiprofissionais e o treinamento de profissionais de saúde. Inovações tecnológicas por si só não garantem avanços na qualidade da assistência ou adoção de práticas alimentares mais saudáveis, tampouco asseguram eliminação de imprecisões no relato da dieta. Indivíduos que não possuam aparelhos eletrônicos com acesso adequado a internet e com dificuldades em responder questionários sem o auxílio de um entrevistador, como crianças, idosos ou pacientes com algum comprometimento cognitivo podem apresentar dificuldades nesses inquéritos.

Integração de informações provenientes de diferentes bases de dados deve ser estimulada e uma realidade mais comum no futuro. Os profissionais de saúde poderão assistir melhor os seus pacientes e com personalização da

assistência. Desta forma, faz-se necessária uma evolução da qualidade dos serviços de telecomunicações no país, desenvolvimento da internet das coisas, ampliação do uso de prontuários eletrônicos, integração dos sistemas de informação em saúde, mensuração de dados clínicos em tempo real e o monitoramento de comportamentos relacionados com o estilo de vida a partir de dispositivos eletrônicos. As informações sobre históricos progresso e atual da saúde, incluindo as avaliações da dieta, podem ser fortalecidas por dispositivos como *tablets*, computadores, *smartwatch* e *smartphones* com câmera embutida, sensores e leitores de código de barras. O uso de aplicativos e *softwares* para reconhecimento de imagens contendo alimentos, combinados aos sistemas de geolocalização e transmissão ágil de informações sobre aquisição e consumo de alimentos também despontam como aplicações promissoras.

Finalmente, regulamentos das condições para uso de todas essas informações, os limites e procedimentos para proteção da sociedade devem ser continuamente debatidos e atualizados. Eles devem seguir o disposto nas melhores práticas para segurança e privacidade dos dados, independentemente de sua origem e finalidade. A participação da sociedade na construção desse debate ajuda no avanço da ciência e nas aplicações dela decorrentes.

CONFLITOS DE INTERESSE

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

REFERÊNCIAS

1. Afshin A, Sur PJ, Fay KA, Cornaby L, Ferrara G, Salama JS, et al. Health effects of dietary risks in 195 countries, 1990–2017: a systematic analysis for the Global Burden of Disease Study 2017. *Lancet*. 2019;393(10184):1958–72. <https://pubmed.ncbi.nlm.nih.gov/30954305/>
2. Otto MCO, Afshin A, Micha R, Khatibzadeh S, Fahimi S, Singh G, et al. The Impact of Dietary and Metabolic Risk Factors on Cardiovascular Diseases and Type 2 Diabetes Mortality in Brazil. *PLoS One*. 2016;11(3):e0151503. <https://pubmed.ncbi.nlm.nih.gov/26990765/>
3. Roth GA, Mensah GA, Johnson CO, Addolorato G, Ammirati E, Baddour LM, et al. Global Burden of Cardiovascular Diseases and Risk Factors, 1990–2019. Update From the GBD 2019 Study. *J Am Coll Cardiol*. 2020;76(25):2982–3021. <https://pubmed.ncbi.nlm.nih.gov/33309175/>
4. Mozaffarian D. Dietary and Policy Priorities for Cardiovascular Disease, Diabetes, and Obesity: A Comprehensive Review. *Circulation*. 2016;133(2):187–225. <https://pubmed.ncbi.nlm.nih.gov/26746178/>
5. Boeing H. Nutritional epidemiology: New perspectives for understanding the diet-disease relationship? *Eur J Clin Nutr*. 2013;67(5):424–9. <https://pubmed.ncbi.nlm.nih.gov/23443832/>
6. Shim J-S, Oh K, Kim HC. Dietary assessment methods in epidemiologic studies. *Epidemiol Health*. 2014;36:e2014009. <https://pubmed.ncbi.nlm.nih.gov/25078382/>
7. Fraser GE. A search for truth in dietary epidemiology. *Am J Clin Nutr*. 2003;78(3 Suppl):521S–5S. <https://pubmed.ncbi.nlm.nih.gov/12936944/>
8. Dekkers AL, Verkaik-Kloosterman J, van Rossum CT, Ocké MC. SPADE, a New Statistical Program to Estimate Habitual Dietary Intake from Multiple Food Sources and Dietary Supplements. *J Nutr*. 2014;144(12):2083–91. <https://pubmed.ncbi.nlm.nih.gov/25320187/>
9. Subar AF, Freedman LS, Tooze JA, Kirkpatrick SI, Boushey C, Neuhauser ML, et al. Addressing Current Criticism Regarding the Value of Self-Report Dietary Data. *J Nutr*. 2015;145(12):2639–45. <https://pubmed.ncbi.nlm.nih.gov/26468491/>
10. Harttig U, Haubrock J, Knüppel S, Boeing H. The MSM program: web-based statistics package for estimating usual dietary intake using the Multiple Source Method. *Eur J Clin Nutr*. 2011;65(Suppl 1):S87–91. <https://pubmed.ncbi.nlm.nih.gov/21731011/>
11. Guenther PM, Kott PS, Carriquiry AL. Development of an Approach for Estimating Usual Nutrient Intake Distributions at the Population Level. *J Nutr*. 1997;127(6):1106–12. <https://pubmed.ncbi.nlm.nih.gov/9187624/>
12. Tooze JA, Midthune D, Dodd KW, Freedman LS, Krebs-Smith SM, Subar AF, et al. A New Statistical Method for Estimating the Usual Intake of Episodically Consumed Foods with Application to Their Distribution. *J Am Diet Assoc*. 2006;106(10):1575–87. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2517157/>
13. Kelly JT, Collins PF, McCamley J, Ball L, Roberts S, Campbell KL. Digital disruption of dietetics: are we ready? *J Hum Nutr Diet*. 2021;34(1):134–46. <https://pubmed.ncbi.nlm.nih.gov/33108029/>
14. Abrahams M, Matusheski NV. Personalised nutrition technologies: a new paradigm for dietetic practice and training in a digital transformation era. *J Hum Nutr Diet*. 2020;33(3):295–8. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7317901/>
15. Panaretos D, Koloverou E, Dimopoulos AC, Kouli GM, Vamvakari

- M, Tzavelas G, et al. A comparison of statistical and machine-learning techniques in evaluating the association between dietary patterns and 10-year cardiometabolic risk (2002-2012): The ATTICA study. *Br J Nutr.* 2018;120(3):326–34. <https://pubmed.ncbi.nlm.nih.gov/29789037/>
16. Hearty AP, Gibney MJ. Analysis of meal patterns with the use of supervised data mining techniques--artificial neural networks and decision trees. *Am J Clin Nutr.* 2008;88(6):1632–42. <https://pubmed.ncbi.nlm.nih.gov/19064525/>
17. Boland M, Bronlund J. eNutrition - The next dimension for eHealth? *Trends Food Sci Technol.* 2019;91:634–9. <file:///C:/Users/ANACAR~1/AppData/Local/Temp/eNutrition.pdf>
18. Zhang W, Yu Q, Siddiquie B, Divakaran A, Sawhney H. "Snap-n-Eat": Food recognition and nutrition estimation on a smartphone. *J Diabetes Sci Technol.* 2015;9(3):525–33. <https://pubmed.ncbi.nlm.nih.gov/25901024/>
19. Zhu F, Bosch M, Schap T, Khanna N, Ebert DS, Boushey CJ, et al. Segmentation assisted food classification for dietary assessment. Bouman CA, Pollak I, Wolfe PJ, editors. *Proc SPIE Int Soc Opt Eng.* 2011;78730B. <https://pubmed.ncbi.nlm.nih.gov/22128304/>
20. Spicer J, Sanborn AN. What does the mind learn? A comparison of human and machine learning representations. *Curr Opin Neurobiol.* 2019;55:97–102. <https://pubmed.ncbi.nlm.nih.gov/30870615/>
21. Witten IH, Frank E, Hall MA. *Data mining practical machine learning tools and techniques.* 3.ed. Morgan Kaufmann, editor. United States: Elsevier; 2011;629
22. Hand DJ, Mannila H, Smith P. *Principles of data mining.* Cambridge, Massachusetts: Press, Cambridge Mass MIT; 2001;546.
23. Alanazi HO, Abdullah AH, Qureshi KN. A Critical Review for Developing Accurate and Dynamic Predictive Models Using Machine Learning Methods in Medicine and Health Care. *J Med Syst.* 2017;41(4):69. <https://pubmed.ncbi.nlm.nih.gov/28285459/>
24. Dunjko V, Briegel HJ. Machine learning & artificial intelligence in the quantum domain: A review of recent progress. *Reports Prog Phys.* 2018;81(7):074001. <https://pubmed.ncbi.nlm.nih.gov/29504942/>
25. Han J, Kamber M, Pei J. *Data mining: Concepts and Techniques.* 3.ed. Burlington, MA, USA: Morgan Kaufmann; 2011;703.
26. Morgenstern JD, Rosella LC, Costa AP, de Souza RJ, Anderson LN. Perspective: Big Data and Machine Learning Could Help Advance Nutritional Epidemiology. *Adv Nutr.* 2021;12(3):621–31. <https://pubmed.ncbi.nlm.nih.gov/33606879/>
27. Mehta N, Pandit A. Concurrence of big data analytics and health-care: A systematic review. *Int J Med Inform.* 2018;114:57–65. <https://pubmed.ncbi.nlm.nih.gov/29673604/>
28. Rajkomar A, Dean J, Kohane I. Machine Learning in Medicine. *N Engl J Med.* 2019;380(14):1347–58. <https://pubmed.ncbi.nlm.nih.gov/30943338/>
29. Mozaffarian D, Rosenberg I, Uauy R. History of modern nutrition science—implications for current research, dietary guidelines, and food policy. *BMJ.* 2018;361:k2392. <https://pubmed.ncbi.nlm.nih.gov/29899124/>
30. Das SK, Miki AJ, Blanchard CM, Sazonov E, Gilhooly CH, Dey S, et al. Perspective: Opportunities and Challenges of Technology Tools in Dietary and Activity Assessment: Bridging Stakeholder Viewpoints. *Adv Nutr.* 2022;13(1):1–15. <https://pubmed.ncbi.nlm.nih.gov/34545392/>
31. Illner A-K, Freisling H, Boeing H, Huybrechts I, Crispim S, Slimani N. Review and evaluation of innovative technologies for measuring diet in nutritional epidemiology. *Int J Epidemiol.* 2012;41(4):1187–203. <https://pubmed.ncbi.nlm.nih.gov/22933652/>
32. Timon CM, van den Barg R, Blain RJ, Kehoe L, Evans K, Walton J, et al. A review of the design and validation of web- and computer-based 24-h dietary recall tools. *Nutr Res Rev.* 2016;29(2):268–80. <https://pubmed.ncbi.nlm.nih.gov/27955721/>
33. Thompson FE, Dixit-Joshi S, Potischman N, Dodd KW, Kirkpatrick SI, Kushi LH, et al. Comparison of Interviewer-Administered and Automated Self-Administered 24-Hour Dietary Recalls in 3 Diverse Integrated Health Systems. *Am J Epidemiol.* 2015;181(12):970–8. <https://pubmed.ncbi.nlm.nih.gov/25964261/>
34. Bel-Serrat S, Knaze V, Nicolas G, Marchioni DM, Steluti J, Mendes A, et al. Adapting the standardised computer- and interview-based 24 h dietary recall method (GloboDiet) for dietary monitoring in Latin America. *Public Health Nutr.* 2017;20(16):2847–58. <https://pubmed.ncbi.nlm.nih.gov/28803598/>
35. Barufaldi LA, Abreu GDA, Veiga GV, Sichieri R, Kuschner MCC, Cunha DB, et al. Programa para registro de recordatório alimentar de 24 horas: aplicação no Estudo de Riscos Cardiovasculares em Adolescentes. *Rev Bras Epidemiol.* 2016;19(2):464–8. <https://www.scielo.br/j/rbepid/a/Zy9YbsHTXtT3WmHqKswky/abstract/?lang=pt>
36. Subar AF, Kirkpatrick SI, Mittl B, Zimmerman TP, Thompson FE, Bingley C, et al. The Automated Self-Administered 24-Hour Dietary Recall (ASA24): A Resource for Researchers, Clinicians, and Educators from the National Cancer Institute. *J Acad Nutr Diet.* 2012;112(8):1134–7. <https://pubmed.ncbi.nlm.nih.gov/22704899/>
37. Steluti J, Crispim SP, Araujo MC, Peralta AM, Pereira RA, Sichieri R, et al. Tecnologia em Saúde: versão brasileira do software GloboDiet para avaliação do consumo alimentar em estudos epidemiológicos. *Rev Bras Epidemiol.* 2020;23:E200013. <https://www.scielo.br/j/rbepid/a/DDF5kZKPwszbBP3ZDDdTh8F/?format=pdf&lang=pt>
38. Kravchychyn A, Machado P, Rhein S, Dâmaso A. Uso de Recursos de Informática e Mídias Sociais para Avaliação do Consumo Alimentar. In: Ribeiro SML, Melo CM de, Tirapegui J, editors. *Avaliação nutricional: teoria e prática.* 2. ed. Rio de Janeiro, RJ: Guanabara Koogan; 2018; 33–7.
39. Mayén A-L, Marques-Vidal P, Paccaud F, Bovet P, Stringhini S. Socioeconomic determinants of dietary patterns in low- and middle-income countries: a systematic review. *Am J Clin Nutr.* 2014;100(6):1520–31. <https://pubmed.ncbi.nlm.nih.gov/25411287/>
40. Giabbanelli PJ, Adams J. Identifying small groups of foods that can predict achievement of key dietary recommendations: data mining of the UK National Diet and Nutrition Survey, 2008-12. *Public Health Nutr.* 2016;19(9):1543–51. <https://pubmed.ncbi.nlm.nih.gov/26879185/>
41. Pencina MJ, Millen BE, Hayes LJ, Agostino RBD. Performance of a Method for identifying the Unique Dietary Patterns of Adult Women and Men: The Framingham Nutrition Studies. *J Am Diet Assoc.* 2009;108(9):1453–60. https://www.researchgate.net/publication/23221719_Performance_of_a_Method_for_Identifying_the_Unique_Dietary_Patterns_of_Adult_Women_and_Men_The_Framingham_Nutrition_Studies
42. Silva VC, Gorgulho B, Marchioni DM, Araujo TA de, Santos IS, Lotufo PA, et al. Clustering Analysis and Machine Learning algorithms in the prediction of dietary patterns: Cross-sectional results of the Brazilian Longitudinal Study of Adult Health (ELSA-Brasil). *J Hum Nutr Diet.* 2022; Online ahead of print. <https://pubmed.ncbi.nlm.nih.gov/35043491/>
43. Tay D, Poh CL, Kitney RI. A novel neural-inspired learning algorithm with application to clinical risk prediction. *J Biomed Inform.* 2015;54:305–14. <https://pubmed.ncbi.nlm.nih.gov/25576352/>
44. Kastorini CM, Papadakis G, Milionis HJ, Kalantzi K, Puddu PE, Nikolaou V, et al. Comparative analysis of a-priori and a-posteriori dietary patterns using state-of-the-art classification algorithms: A case/case-control study. *Artif Intell Med.* 2013;59(3):175–83. <https://pubmed.ncbi.nlm.nih.gov/24080079/>
45. Basnet TB, Srijana GC, Basnet R, Neupane B. Dietary nutrients of relative importance associated with coronary artery disease: Public health implication from random forest analysis. *PLoS One.* 2020;15(12):e0243063. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7728256/>
46. Biesbroek S, van der A DL, Brosens MC, Beulens JW, Verschuren WM, van der Schouw YT, et al. Identifying cardiovascular risk factor-related dietary patterns with reduced rank regression and random forest in the EPIC-NL cohort. *Am J Clin Nutr.* 2015;102(1):146–54. <https://pubmed.ncbi.nlm.nih.gov/25971717/>

ATUAÇÃO DO ASSISTENTE SOCIAL FRENTE A NOVAS TECNOLOGIAS DE INTELIGÊNCIA ARTIFICIAL: DISPOSITIVOS DE ASSISTÊNCIA CIRCULATORIA MECÂNICA - DACM

*PERFORMANCE OF THE SOCIAL WORKER IN THE FACE OF NEW ARTIFICIAL
INTELLIGENCE TECHNOLOGIES: MECHANICAL CIRCULATORY
ASSIST DEVICES - MCAD*

Monica Pompiani¹
Ana Lucia da Silva Ribeiro¹
Ednalva Moreira da Silva¹
Suellen Cristina de Jesus
Silva¹
Diego Vinicius Cassiano
Barbosa²

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

2. Grupo Executivo de Assistência
Patronal – GEAP Saúde - Ahm.
São Paulo, SP, Brasil.

Correspondência:
Monica Pompiani.
mobtu@hotmail.com

RESUMO

A presença de produtos inteligentes vem crescendo nos últimos anos e sua empregabilidade é pouco conhecida no campo da saúde, de modo que grande parcela da população desconhece que a inteligência artificial está presente nos aparelhos que nos levam a diagnósticos mais precisos e nos dispositivos que atuam no prolongamento da vida. O objetivo deste artigo está direcionado a explicar a atuação profissional do assistente social no processo de seleção do paciente candidato ao implante de dispositivos e, como metodologia, utilizou-se a pesquisa bibliográfica e de observação empírica do cotidiano profissional. O número de pessoas com cardiopatias é significativo e muitos evoluem para as insuficiências cardíacas avançadas resistentes aos tratamentos otimizados, necessitando de tratamentos mais agressivos, como o transplante cardíaco que, por sua vez, esbarra em certas limitações, tais como a falta de doadores. Os Dispositivos de Assistência Circulatoria Mecânica (DACMs) passam a ser uma realidade terapêutica alternativa. Os candidatos ao DACM devem ser avaliados quanto à presença de fatores que possam contraindicar ou influenciar a sobrevida após o implante, analisando aspectos clínicos, estado emocional do paciente e fatores externos, os determinantes sociais que o permeiam. O trabalho da equipe multidisciplinar, na qual o assistente social está inserido, é determinante na qualidade da assistência e no êxito do tratamento. O assistente social atua diretamente na identificação desses determinantes, os quais influenciam a organização social do paciente e de sua rede familiar, e conseqüentemente em seu processo de enfrentamento da patologia.

Descritores: Serviço Social; Inteligência Artificial; Insuficiência Cardíaca; Pesquisa Multidisciplinar.

ABSTRACT

The presence of smart products has been growing in recent years and their usability is little known in the health care field, such that a large portion of the population is unaware that artificial intelligence is present in the devices that lead us to more accurate diagnoses and that act in prolonging life. The objective of this article is to explain the professional performance of the social worker in the process of selecting patients who are candidates for device implantation. The methodology was based on bibliographical research and empirical observation of the daily professional routine. The number of people with heart disease is significant and many evolve to advanced heart failure resistant to optimized treatments, requiring more aggressive treatments, such as heart transplantation, which in turn comes up against certain limitations, such as the lack of donors. Mechanical Circulatory Assist Devices (MCAD) have become an alternative therapeutic reality. Candidates for MCAD must be evaluated for the presence of factors that may contraindicate or influence survival after implantation, by analyzing clinical aspects, the patient's emotional state, and external factors, the social determinants that permeate it. The work of the multidisciplinary team, of which the social worker is a

member, is decisive in the quality of care and in the success of the treatment. The social worker acts directly in the identification of these determinants, which influence the social organization of the patient and their family network, and consequently their process of coping with the pathology.

Keyword: Social Work; Artificial Intelligence; Heart Failure; Multidisciplinary Research.

O presente artigo tem como objetivo explicar sobre a atuação profissional do assistente social no processo de seleção do paciente candidato ao implante de Dispositivo de Assistência Circulatória Mecânica, dotado de tecnologia pouco conhecida no campo da saúde, a inteligência artificial. Para construção deste, utilizou-se de pesquisa bibliográfica e de observação empírica do cotidiano profissional, realizada no Serviço Social do Instituto do Coração do Hospital das Clínicas da Faculdade de Medicina da Universidade de São Paulo (InCor / HCFMUSP) em Janeiro de 2022.

No contexto atual, muito se fala em Inteligência Artificial (IA), questão atenuada pelo momento de pandemia, em que se busca por tecnologias mais ágeis e eficazes nas diversas áreas do cotidiano moderno. A presença de produtos inteligentes, resultantes dos avanços da microeletrônica, a digitalização, a internet das coisas e o uso da mesma como plataforma de comunicação, propiciam uma ferramenta oportuna para criar um ambiente inteligente com interação preditiva nas decisões médicas em pacientes. Sua empregabilidade, por vezes, é desconhecida, como por exemplo, no campo da saúde, de modo que grande parcela da população desconhece que a IA está presente nos aparelhos que nos levam a diagnósticos mais precisos, nos dispositivos que atuam no prolongamento da vida e, em demais ações da medicina contemporânea.^{1,2}

A Inteligência Artificial (IA) deve ser usada como uma ferramenta cujo objetivo é promover a qualidade de vida, a saúde e o bem-estar dos seres humanos. É resultante da combinação da computação e de modelos matemáticos sofisticados, para produzir algoritmos capazes de imitar a inteligência humana, personalizando seus equipamentos de acordo com suas especificidades. Esta tecnologia aliada à outras informações, tais como, à fisiologia do paciente, à técnica de implante a ser realizado e, ainda, os diferentes tipos de dispositivos existentes, que direcionadas para uma base de conhecimento comum que permite uma correlação e padrões para avaliações descritivas, promovendo melhores parâmetros de apoio à decisão e o acompanhamento da condição de saúde do paciente.^{1,2} Ela surge com significativo papel na tomada de decisões no processo de saúde e doença do paciente, valendo a pena salientar que, tal processo é passível de falhas, e suas decisões nem sempre são compreensíveis para os seres humanos, seu desempenho e margem de erros devem sempre ser informados aos pacientes antes de tomar decisões acerca de sua saúde e a da construção conjunta de seu plano terapêutico.¹

Na cardiologia, várias aplicações se mostraram exitosas, uma delas é a identificação de insuficiência cardíaca (IC) em pacientes através dos resultados de exames de eletrocardiogramas e ecocardiogramas que se apresentam como alternativas tecnológicas ao tratamento, se configurando como elemento fundamental no processo diagnóstico e

sequência dos cuidados ofertados aos pacientes, ao passo que, no avançar diário das novas tecnologias clínicas, os novos dispositivos vem assumindo concomitantemente às demais terapêuticas tradicionais, uma função de extrema relevância nos diversos tipos de tratamentos.¹

A IC trata-se de uma síndrome clínica complexa, com alta prevalência global, na qual o coração trabalha de forma insuficiente para bombear sangue com a finalidade de atender às necessidades do metabolismo corpóreo, com a dificuldade do oxigênio em se disseminar aos demais órgãos e tecidos, o (a) paciente acomete-se de diversos sintomas que implicam em suas atividades básicas de vida diária, respectiva qualidade de vida e, em sua funcionalidade geral.³

Com elevada taxa de morbimortalidade observada nos indicadores da Organização Mundial de Saúde (OMS), onde cerca de 23 milhões de pessoas sofrem com a doença, torna-se possível a classificação deste cenário em uma questão de saúde pública mundial, haja vista que, o desenvolvimento desta e de outras cardiopatias podem ser de base congênita, porém em suma, grande parte da população a desenvolve ao longo do percurso existencial em função das condições de vida de nossa sociedade. Só no Brasil são aproximadamente 100 mil novos casos anualmente.⁴

Existe um número significativo de pacientes que evoluem para um quadro de IC avançada. Quando esta torna-se resistente ao tratamento otimizado demanda-se para um tratamento mais agressivo, como o Transplante Cardíaco (TC), que por sua vez esbarra em limitações importantes, como a falta de doadores, a escassez de centros transplantadores no Brasil e as contraindicações, mais frequentes em pacientes com idade acima de 65 anos.³⁻⁵

Consequentemente, a insuficiência cardíaca (IC), é um diagnóstico que pode levar a indicação da utilização de Dispositivos de Assistência Circulatória Mecânica (DACM) que se materializa através da tecnologia IA.^{1,2}

Para pacientes contraindicados ou com impossibilidade de realização do TC em curto prazo, os DACM se tornaram uma realidade terapêutica alternativa, aos pacientes sem condições clínicas de transplante com IC refratária, o dispositivo é utilizado como terapia de destino, possibilitando maior sobrevida e melhor qualidade de vida, em analogia ao tratamento clínico medicamentoso. Porém, por se tratar de uma tecnologia recente, sua incorporação em nosso país se torna inviável devido ao alto custo, poucas equipes tem a capacitação e as estruturas hospitalares adequadas.⁵ Apesar da mão de obra já ser disponibilizada pelo nosso Sistema Único de Saúde – SUS, o equipamento ainda não dispõe de viabilidade econômica para concessão via sistema público de saúde no Brasil.

Entende-se que o sistema de saúde no Brasil, apesar do adjetivo “único”, é composto por estabelecimentos e serviços vinculados a organizações públicas e privadas, estas com fins lucrativos ou não.⁶

A dispensação de medicamentos, materiais e equipamentos pelo SUS estão ligados diretamente ao plano terapêutico proposto para garantir o tratamento de forma eficaz, entretanto há normas a serem seguidas. Normas estas que estão ditadas pelo Governo Federal através da LEI Nº 12.401, DE 28 DE ABRIL DE 2011. Em seu Art. 19-Q há a explanação de que “a incorporação, exclusão ou alteração pelo SUS de novos medicamentos, produtos e procedimentos, bem como a constituição ou a alteração de protocolo clínico ou de diretriz terapêutica, são atribuições do Ministério da Saúde, assessorado pela Comissão Nacional de Incorporação de Tecnologias no SUS”.⁷

Para liberação de tais equipamentos levam em consideração as evidências científicas sobre a eficácia, a efetividade e segurança do dispositivo e a avaliação econômica comparativa aos custos benefícios em relação às tecnologias já incorporadas. Sendo assim, os DACM, por se tratar de uma tecnologia recente em nosso país, é um equipamento que ainda não se enquadra nas normas do Governo Federal, sendo seu custo inviável para aquisição até o momento.⁷

Os DACM consistem em uma bomba mecânica implantada cirurgicamente no coração do paciente, permitindo a estabilização hemodinâmica com redução de pressões de enchimentos ventriculares, diminuição de pré-carga e normalização da pressão arterial. Esta bomba é constituída de cânulas formando bombas de sangue que circulam através de um aparelho externo ao corpo humano e utiliza-se de fonte de energia externa para realizar sua atividade. Eles se apresentam em diversos modelos, sendo que no Brasil temos apenas três: HeartMate II, INCOR e HeartWare, disponibilizado pelas empresas Thoratec, Berlin Heart e HeartWare, respectivamente.³⁻⁵

Para implantação dos DACM é necessária uma avaliação minuciosa do paciente, pois existem critérios para sua indicação. Dentro da análise clínica deve-se considerar o tempo de espera em filas para TC, avaliando o custo-benefício de sua utilização. Os candidatos devem ser avaliados quanto a presença de fatores que possam contraindicar ou influenciar na sobrevida após o implante.⁵ Além do aspecto clínico deve-se levar em consideração os fatores externos e estado emocional do paciente. Analisar os determinantes sociais que o permeiam é primordial para o êxito do tratamento.

O trabalho da equipe multidisciplinar durante todo processo faz a diferença, sendo determinante na qualidade da assistência e no êxito do tratamento. Na avaliação pré-implante busca-se conhecer o potencial de sucesso do candidato e identificar riscos ao tratamento. Conforme recomendado na literatura, pacientes e cuidadores são avaliados quanto a vínculo afetivo, capacidade cognitiva, compreensão da doença, motivação, proposta terapêutica, adesão aos tratamentos e suporte social e emocional, por meio de entrevistas e instrumentos sociais específicos.³

O modo como o indivíduo responde ao processo de adoecimento está interligado às condições de vida. Para exercer o papel de avaliador social, conta-se com o profissional de Serviço Social, que se faz importante na identificação dos determinantes sociais em saúde que se constituem a partir dos eixos: econômicos, culturais, habitacionais, educacionais e políticos, e, que possuem influência direta na organização social do paciente e de sua rede familiar, e conseqüente em seu processo de enfrentamento da patologia.⁸

A inserção do Serviço Social na saúde se deu por meio da construção do exercício de um profissional a partir de modelos médicos, o qual poderia contribuir para o seu aperfeiçoamento. Indo para área da saúde propriamente dita, o Serviço Social surge nos hospitais com a demanda de construir um elo entre instituições, profissionais e pacientes, visando garantir à adesão ao tratamento pós alta hospitalar, através de ações fundamentais de orientações e encaminhamentos ao paciente e família, e a árdua articulação entre políticas públicas intersetoriais.^{9,10}

A área da saúde pública, é um espaço sócio-ocupacional de grande relevância e alto índice de empregabilidade para o assistente social, sendo a quarta categoria de nível superior na composição das equipes de saúde, ficando no quantitativo de contratações atrás apenas dos médicos, dentistas e enfermeiros, segundo dados apresentados em II Encontro Estadual de Assistentes Sociais da Secretaria de Estado de Saúde Pública/RN-SSA. A práxis profissional inerentes às situações sociais dos pacientes e suas famílias, fazem com que as unidades de gerenciamento dos serviços de saúde, em todos os níveis de complexidade, apontem a necessidade da ação dos profissionais na composição das equipes de saúde, partindo do pressuposto da visão holística do adoecimento, e das diversas dimensões que permeiam o sujeito nas esferas biopsicossocial.¹¹

Como membro da equipe multidisciplinar, o assistente social desenvolve estratégias de atendimento global, traçando metas de intervenção para favorecer a efetivação de direitos que auxiliarão na adesão ao tratamento proposto, participando do padrão institucional dos serviços prestados.⁸⁻¹² Sua contribuição deve ocorrer a partir de seu olhar técnico especializado e diferenciado em relação aos pacientes e sua condição de vida, com competência distinta para o encaminhamento das ações, o que o diferencia dos demais membros da equipe de saúde.¹³

O Serviço Social na área da saúde passa pela compreensão dos determinantes sociais, econômicos e culturais que interferem no processo saúde-doença e na busca de estratégias político-institucionais para o enfrentamento dessas questões. O exercício profissional do assistente social não deve desconsiderar as dimensões subjetivas vividas pelo usuário.¹⁴

Ao adentrar a uma unidade hospitalar, o paciente não se resume apenas à doença para qual busca tratamento, ele possui uma história que compõem sua trajetória de vida dentro de uma realidade social vivenciada apenas por ele. Acessar os aspectos particulares do cotidiano deste paciente só é possível através do acolhimento.⁸

AVALIAÇÃO SOCIAL

A solicitação parte da equipe médica, após a identificação de condicionantes clínicos para o dispositivo, sendo direcionada ao paciente e estendendo para o meio familiar, com a indicação e identificação do cuidador.⁵

O instrumental utilizado para coleta de dados se concentra na entrevista e se divide em dois momentos: perfil sociodemográfico e critério de elegibilidade. Como toda ação leva a uma intencionalidade, é desejável que esta prática levante quesitos que não só orientam a compreensão da dinâmica social, mas possibilitam desvendar demandas implícitas à realidade aparente.⁸⁻¹²

O perfil sociodemográfico é a identificação do indivíduo em variáveis diretas, como idade, sexo, estado civil, nacionalidade, dentre outras. Já o critério de elegibilidade é extraído do cotidiano do paciente, apontando as condicionantes sociais. Para melhor analisar estes requisitos, dividiu-se em quatro blocos temáticos:¹²

Aceitabilidade: avalia-se a proposta terapêutica junto ao paciente e família. Ambos necessitam de informações para tomada de decisão. Este bloco é realizado pela equipe multidisciplinar. Nesta fase, o assistente social realiza a orientação como um todo, desde as normas institucionais como a importância na adesão ao programa possibilitando uma melhora na qualidade de vida.¹²

Acessibilidade: diz respeito ao acesso do paciente aos serviços de saúde, seja à Instituição hospitalar para o implante, manutenção do equipamento e possíveis intercorrências ou às unidades de saúde para curativos, medicações e materiais.¹²

Condições socioeconômicas: a variável renda, as condições de moradia e situação empregatícia são avaliadas neste momento, onde os dificultadores implicam significativamente para a adesão ao plano terapêutico. A renda está relacionada ao recurso financeiro que o paciente e/ou sua família dispõe para as despesas familiares e possíveis gastos relacionados ao tratamento.¹²

Em relação ao aspecto habitacional, abordam-se requisitos para uma infraestrutura adequada ao tratamento. E, quanto à situação empregatícia, busca-se entender como se dá a relação do paciente com o mundo do trabalho, e a partir daí seguir com as orientações de acesso à benefícios sociais contributivos, caso haja o retrospecto de contribuições à previdência social. Quando não há, as orientações se redirecionam ao acesso à benefícios de cunho não contributivos, com critérios de elegibilidade mais específicos que parte de análise socioeconômica do núcleo familiar.⁸⁻¹²

Dinâmica familiar: permite constatar com quem o paciente reside e qual a configuração familiar correspondente ao seu núcleo, podendo identificar a retaguarda de cuidados disponível. Esta condiciona-se aos vínculos afetivos e ao papel que o paciente exerce na família. O processo de adoecimento de um membro familiar provoca alterações internas instituindo uma nova organização nesse núcleo, que por vezes, é preciso ressignificar seus papéis intrafamiliares. Identifica-se quem se disponibilizará para desempenhar o papel de cuidador, que por sua vez auxiliará nas tomadas de decisões e na organização dos cuidados em conjunto com a equipe multiprofissional.⁸⁻¹²

O cuidador, na maioria das vezes, é um membro da família do enfermo, sendo denominado de cuidador-familiar. Este receberá a corresponsabilidade de cuidar juntamente com a equipe de saúde. A função social do cuidador apresenta-se como extensão naturalizada dos perfis maternos, conjugal ou mesmo filial, território íntimo no qual não se admitem recusas.¹⁵ No processo de avaliação do candidato ao implante do dispositivo, a ausência de cuidador é considerada uma contraindicação absoluta.⁵

Durante todo a avaliação o assistente social realiza ações socioeducativas facilitando a compreensão e o convívio do processo saúde/doença através de orientações sobre a mudança de hábitos, busca por recursos externo de rede de apoio, tanto de saúde quanto assistenciais, e a sua posição enquanto sujeito dotado direitos, e neste caso específico, o

direito à vida, visando o aprendizado no manuseio e manutenção do dispositivo, para atingir melhor qualidade de vida.⁸⁻¹²

Portanto, nota-se o grau de relevância da avaliação social para seleção dos pacientes e, conseqüentemente, efetivação da proposta terapêutica. O que corrobora com a literatura no que tange à extrema necessidade de avaliação e assistência multiprofissional neste processo.¹⁶

CONSIDERAÇÕES FINAIS

Com base na discussão apresentada, observa-se que através do avanço tecnológico e o incremento de novos métodos de execução, há o surgimento de equipamentos programados para funcionar sem a intervenção humana, a partir da inteligência artificial, que surge como alternativa ao tratamento convencional, mas ainda esbarram na viabilidade econômica de sua plena implementação.

Destaca-se neste estudo a práxis do Serviço Social na Saúde enquanto membro da equipe multiprofissional e, sobretudo, a atuação na avaliação social para implante do DACM. Este profissional desenvolve um papel de extrema relevância em todas as etapas do processo, principalmente no que tange ao estudo social prévio à identificação dos candidatos, pois um dos fatores contraindicativos é a fragilidade ou inexistência de uma rede social de apoio atuante.

Embora a Diretriz Brasileira de Assistência Circulatória Mecânica de 2016 indique uma complexa avaliação multiprofissional do paciente para elegibilidade ao DACM, com a finalidade de aferir histórico, compreensão da condição clínica, função cognitiva, motivação, adesão ao tratamento farmacológico e não farmacológico, suporte social e emocional, dentre outros, ao longo do estudo não foi possível identificar à inserção do Serviço Social em seu escopo de categorias profissionais e protocolos, o que por sua vez, pode ser considerado um ponto a ser revisto e, aprimorado, nas próximas edições de seus manuais.

Observou-se também à insuficiência de pesquisas tanto sobre Inteligência Artificial quanto de DACM na área do Serviço Social e, apesar da escassez de produções da categoria sobre a temática, compreensível em função de ser algo novo no âmbito clínico, mas segue como uma provocação às produções científicas da classe sobre essa temática a partir da disseminação dessa alternativa terapêutica que tende a se difundir nos próximos anos.

Percebeu-se a necessidade de fomentar o conhecimento acerca da atuação do assistente social no processo de implante do DACM, almejando ampliar os horizontes e o acesso à informação para aqueles que se encontram na fila de espera por um transplante cardíaco.

Outra reflexão importante se refere a um obstáculo notado no curso da pesquisa, no tocante aos aspectos limitadores à expansão dessa alternativa terapêutica, que esbarram nas questões econômicas de sua disseminação no sistema público de saúde. Porém, não se pode perder de vista que o dispositivo, já se encontra no Brasil e apresenta indicadores positivos frente à determinada cardiopatia.

Conclui-se que as novas tecnologias de inteligência artificial se tratam de alternativas de cuidado fundamentais à melhora da qualidade de vida do paciente, trazendo consigo grande impactos positivos no enfrentamento da insuficiência cardíaca, refletindo diretamente na retomada da funcionalidade dos pacientes e respectivamente em sua qualidade

de vida e reintegração da vida em sociedade de forma ativa. Dessa forma, é imprescindível que a equipe multiprofissional se aproprie acerca de novas tecnologias que envolvem o cuidado ao paciente cardiopata para fornecer uma assistência direcionada e efetiva em sua plena reabilitação.

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. Ética, Inteligência Artificial e Cardiologia. *Arq Bras Cardiol.* 2020;115(3):579-83. Disponível em: <https://www.scielo.br/abc/a/ZXcY7GKRpnKdzQT46DqvF7z/?lang=pt&format=html#.DOI:https://doi.org/10.36660/abc.20200143>.
2. Dias JC, Dias JC. Ambiente inteligente de tomada de decisão médica para pacientes com dispositivo de assistência ventricular (DAV) no contexto da saúde 4.0. *RPS.* 2019;11:67-83. Disponível em: <https://fatecpg.edu.br/revista/index.php/ps/article/view/27>.
3. Lemos DMP, Barcellos RA, Borba DSM, Caballero LG, Goldraich LA, Echer IC. Comunicação efetiva para o cuidado seguro ao paciente com implante de dispositivo de assistência ventricular. *Rev Gaúcha Enferm.* 2019;40(spe): e20180344. Disponível em: <https://doi.org/10.1590/1983-1447.2019.20180344>.
4. Souza Jr P. Dispositivos de assistência circulatória mecânica: esperança no tratamento da IC avançada. *Pebmed.* 2018. Disponível em: <https://pebmed.com.br/dispositivos-de-assistencia-circulatoria-mecanica-esperanca-no-tratamento-da-ic-avancada/>
5. Ayub-Ferreira SM, Souza NetoJD, Almeida DR, Biselli B, Avila MS, Colafranceschi AS, et al. Diretriz de Assistência Circulatória Mecânica da Sociedade Brasileira de Cardiologia. *Arq Bras Cardiol.* 2016;107(2 Suppl 2):1-33. <https://pubmed.ncbi.nlm.nih.gov/27627754/>
6. Paim JS. O que é SUS. Rio de Janeiro: Editora Fio Cruz, 2015;93. <https://portal.fiocruz.br/livro/o-que-e-o-sus-e-book-interativo>
7. Brasil. LEI Nº 12.401, DE 28 DE ABRIL DE 2011. Altera a Lei nº 8.080, de 19 de setembro de 1990, para dispor sobre a assistência terapêutica e a incorporação de tecnologia em saúde no âmbito do Sistema Único de Saúde – SUS [Acessado 20 de janeiro 2022]. Disponível em http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2011/lei/l12401.htm.
8. Lopes FS, Afonso CA, Alves AMT. Pacientes com diagnóstico oncológico: avaliação social e intervenção do Assistente Social. In: Andrade L, organizadora. *Serviço Social na área da Saúde, construindo registros de visibilidade.* Vol. I. São Paulo: Alumiari. 2019;103-12.
9. Matos MC. *Serviço Social, ética e saúde: reflexões para exercício profissional.* 2. ed. São Paulo: Cortez. 2017;166.
10. Nogueira ACC, Monteiro MVC. Família e Atenção em Saúde: Proteção, Participação ou Responsabilidade? In: Silva LB, Ramos A, organizadoras. *Serviço Social, Saúde e questões contemporâneas: reflexões críticas sobre a prática profissional.* Campinas: Papel Social. 2013; 139-63.
11. Costa MDH. O Trabalho nos Serviços de Saúde e a Inserção dos(as) Assistentes Sociais. In: Mota AE et al. organizadores. *Serviço Social e Saúde.* São Paulo: Cortez. 2009; 304-51.
12. Silva EA, Ribeiro ALS. Avaliação Social em pacientes na fase pré e após o transplante cardíaco. In: Anjos AL, Silva RA, Amaral AS, organizadores. *Políticas Sociais e Políticas Públicas: serviço social compromisso com os direitos sociais e humanos.* São Paulo: Roseli Albuquerque Silva: Ana Lucia dos Anjos. 2021; 88-95.
13. Silva LB, Mendes AG. *Serviço Social, Saúde e Interdisciplinaridade: algumas questões para o debate.* In: Silva LB, Ramos A, organizadoras. *Serviço Social, Saúde e questões contemporâneas: reflexões críticas sobre a prática profissional.* Campinas: Papel Social. 2013;49-64.
14. CFESS. *Parâmetros para Atuação de Assistentes Sociais na Política de Saúde.* Brasília: Conselho Federal de Serviço Social. 2014;79.
15. Valente MT. *Novas configurações familiares: desafios em saúde.* In: Andrade L, organizadora. *Serviço Social na área da Saúde, construindo registros de visibilidade.* Vol I. São Paulo: Alumiari. 2019; 41-52.
16. Machado RC, Gironés P, Souza AR, Moreira RSL, von Jakitsch CB, Branco JNR. Protocolo de cuidados de enfermagem a pacientes com dispositivo de assistência ventricular. *Rev Bras Enferm.* 2017; 70(2):335-41. <https://www.scielo.br/j/reben/a/KfVBT5PF83p7kjbJtZBqT7v/?format=pdf&lang=pt>

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

