

ATUALIZAÇÃO DE TEMA



Inteligência Artificial em Cardiologia: do Teorema de Bayes às Redes Neurais de Aprendizado Profundo

Artificial Intelligence in Cardiology: From Bayes' Theorem to Deep Learning Neural Networks

Larissa Gonçalves Coutinho^{1*}, João Paulo dos Santos Mauler¹, Daniel Gomes Braga dos Reis¹, Marcelo Góes Alves da Silva²

¹Programa de Residência Médica de Cardiologia do Hospital Santa Izabel (HSI); ²Serviço de Hemodinâmica e Cardiologia Intervencionista do HSI; Salvador, Bahia, Brasil

Este artigo de atualização tem como objetivo fornecer uma revisão sobre a evolução e o estado atual da inteligência artificial com foco nas suas aplicações em cardiologia. Recapitulamos sucintamente o histórico da inteligência artificial, desde as suas primeiras aplicações, passando pelos sistemas históricos baseados em lógica bayesiana até as recentes evoluções no que tange ao aprendizado de máquina, aprendizado profundo e as aplicações da ciência de dados e “big data”. Descrevemos achados de recentes estudos sobre o tema, que demonstram a grande aplicabilidade da ciência da computação à prática médica, auxiliando a tomada de decisão e na interpretação de exames de imagem através das redes neurais. Relatamos como os modelos de inteligência artificial já ajudam o processo de tomada de decisão médica em cardiologia e como, no futuro, este processo poderá sofrer uma radical mudança de paradigma, o princípio do qual já estamos testemunhando.

Palavras-chave: Cardiologia; Aprendizado de Máquina; Inteligência Artificial; Redes Neurais.

Correspondence addresses:

Dra. Larissa Coutinho
laara.gc10@hotmail.com

Received: September 22, 2023

Revised: November 16, 2023

Accepted: November 28, 2023

Published: December 27, 2023

Data Availability Statement:

All relevant data are within the paper and its Supporting Information files.

Funding: This work was the result of authors' initiative. There was no support of research or publication funds.

Competing interests: The authors have declared that no competing interests exist.

Copyright

© 2023 by Santa Casa de Misericórdia da Bahia.
All rights reserved.
e-ISSN: 2764-2089
ISSN: 2526-5563

In this paper, we aim to provide an update on artificial intelligence's evolution and current state, focusing on its applications in cardiology. We have recapitulated the history of artificial intelligence, from its first applications through historical systems based on Bayesian logic to recent developments in machine learning, deep learning, and the applications of data science and "big data". We describe findings from recent studies on the topic, which demonstrate the great applicability of computer science to medical practice, decision-making, and interpretation of image exams through neural networks. We report how artificial intelligence models are already helping the medical decision-making process in cardiology and how, in the future, this process could undergo a radical paradigm shift, the beginning of which we are already witnessing.

Keywords: Artificial Intelligence; Cardiology; Machine Learning; Neural Networks.

Introdução

Apesar de ser fato geralmente aceito que o matemático britânico Alan Turing lançou as bases do que chamou de “inteligência de máquina” na primeira metade da década de 1940, infelizmente o trabalho onde ele fez

isto perdeu-se no tempo.¹ Postula-se que o termo “inteligência artificial” tenha sido utilizado oficialmente pela primeira vez em 1955, em uma carta-proposta elaborada pelo matemático e cientista da computação estadunidense John McCarthy. Na ocasião, em conjunto com alguns colegas, ele decidiu abordar a Fundação Rockefeller para requisitar fundos a fim de realizar um seminário sobre o tema no **Dartmouth College** de Hanover, nos Estados Unidos da América.²

Muitos frutos foram colhidos no campo da inteligência artificial após o seminário do **Dartmouth College**, sendo um deles a percepção de que algumas áreas da atividade e do conhecimento humanos pareciam especialmente atrativas como desafios para a “inteligência” das máquinas. Não por acaso, atividades que exigiam grande capacidade de cálculo e raciocínio, como por exemplo a criptografia e os jogos de estratégia (notadamente o xadrez), figuraram em protagonismo nos primeiros experimentos com sistemas computadorizados de inteligência artificial e tomada de decisão. Os primeiros programas de computador capazes de jogar xadrez de acordo com as regras oficiais do jogo, por exemplo, surgiram na primeira metade da década de 1950, e tinham ao seu dispor apenas um frágil algoritmo, que efetuava cálculos básicos chegando a uma avaliação quantitativa das posições sobre o tabuleiro, e percorria uma árvore de decisão (chamada de “**grafo**” no jargão da ciência da computação), selecionando a melhor sequência de jogadas. Tal algoritmo tomava a decisão a respeito de qual lance executar baseado em um processo que envolvia apenas uma lógica do tipo estrutura de seleção condicional (“se... então...”). Sempre houve quem achasse que, no xadrez, a máquina jamais derrotaria os melhores jogadores humanos, porém pouco mais de quarenta anos depois, em 1997, o então campeão mundial de xadrez Garry Kasparov foi derrotado no jogo dos reis pelo computador “*Deep Thought*” da IBM em um match em Nova Iorque.

Pouco tempo após surgirem as primeiras proposições e explorações sobre o tema, desenvolveu-se a ideia de tentar aplicar a inteligência artificial ao conhecimento médico. Nada parecia mais lógico, uma vez que se supunha que uma máquina capaz de armazenar grande quantidade de dados sobre sinais, sintomas, achados de exames, doenças e tratamentos, fosse também capaz de chegar a um diagnóstico de uma maneira puramente sistemática e computacional. As primeiras tentativas de se aplicar a inteligência artificial à medicina foram feitas através do que se chama de “sistema especialista” (uma tradução da expressão “*expert system*” em língua inglesa). Tais sistemas combinavam uma estratégia de estruturas de seleção com bancos de dados contendo centenas ou milhares de dados epidemiológicos como prevalências de doenças e razões de verossimilhança (*likelihood ratios*) para diversos sinais e sintomas, bem como achados de exames laboratoriais para o diagnóstico de diversas doenças. Aplicando-se sucessivamente o teorema de Bayes (ou regra de Bayes, em sua forma que emprega chances – *odds* – no lugar de probabilidades), era possível atualizar sucessivamente a probabilidade pré-teste de determinado diagnóstico através da conhecida equação:³

$$P(A|B) = \frac{P(B|A) P(A)}{P(B)}$$

Como os computadores são muito aptos a realizar cálculos matemáticos, com muito mais precisão e rapidez que o cérebro humano, parecia evidente que tornar-se-iam exímios especialistas em diagnósticos. A lenda que narra a origem do jogo de xadrez conta que a dimensão da recompensa solicitada pelo inventor do jogo crescia exponencialmente, cada parcela dobrando o seu valor conforme se progredia pelas casas do tabuleiro. De forma semelhante, o grafo a ser percorrido para diagnosticar todos os possíveis males que acometem o ser humano, a partir de dados epidemiológicos e um relato de sinais e sintomas, achados de exame

físico e de exames complementares, torna-se rapidamente muito grande, compondo um problema que cresce vertiginosamente em tempo não polinomial (NP); ou seja, rapidamente torna-se, para todos os efeitos, incomputável.⁴ Passado o entusiasmo inicial, ficou claro que os primeiros sistemas especialistas não tinham melhor performance que os médicos humanos, e, portanto, limitar-se-iam a um número bastante restrito de aplicações, umas poucas doenças, aproximações ou meras demonstrações de casos particulares, além de estarem muito sujeitos ao erro.


A este ponto, necessário faz-se dizer que a pesquisa na área de inteligência artificial passou por dois rigorosos “invernos”, de 1974 a 1980 e de 1987 ao ano 2000. Tais períodos corresponderam a espaços de tempo em que decresceu grandemente o incentivo ou o interesse no tema, por diversas razões: falta de fundos, limitações dos primeiros algoritmos e, sobretudo, limitações tecnológicas. Pontos de inflexão que permitiram a retomada do entusiasmo na pesquisa e no desenvolvimento da tecnologia em inteligência artificial, foram o aparecimento e a popularização da internet, as tecnologias de digitalização, compactação e transmissão rápida de grande quantidade de dados e o crescimento exponencial da capacidade de armazenamento e processamento (*very large scale integration* – integração em muito alta escala), com o barateamento dos *chips* de memória e o surgimento de unidades de processamento gráfico (*graphics processing units* - GPUs). As GPUs, apesar de terem sido concebidas para uso sobretudo na indústria dos *video-games*, curiosamente prestam-se muito bem à modelagem de redes neurais, por terem especial vantagem na rápida realização das complexas operações matemáticas necessárias. Uma GPU moderna comercialmente disponível no momento da elaboração deste artigo pode realizar até cerca de 6 trilhões de operações matemáticas em aritmética de ponto flutuante por segundo (teraFLOPS) (Figura 1).

Redes Neurais Artificiais, Aprendizado (profundo) de Máquina e “Big Data”

Uma rede neural artificial é um modelo ou sistema computacional inspirado no sistema nervoso central (mais precisamente, no cérebro) dos mamíferos. Como tal, são capazes de reconhecer padrões em forma de mensagens que nos chegam (no caso do cérebro humano) pelos cinco sentidos: imagens, sons, odores, sabores e sensações táteis. O processo neurológico que leva a esse reconhecimento de padrões é modelado como ocorrendo em “camadas”: há uma camada inicial que transforma, por exemplo, a intensidade luminosa em impulsos elétricos (retina), uma outra camada que reconhece formas e cores, uma terceira camada que estabelece o significado da imagem (perigo, alimento, família, predador) e, assim sucessivamente, até uma camada final que estabelece e adota um curso de ação necessário: aproximação, fuga, luta (Figuras 2-4).

As redes neurais artificiais são úteis, assim como as redes neurais naturais, para resolver problemas de classificação de um grande número de dados discretos, ou também problemas de regressão, para dados contínuos. Por exemplo, após analisar uma grande quantidade de eletrocardiogramas, em um processo chamado de “treinamento”, uma rede neural pode determinar se um determinado eletrocardiograma qualquer provavelmente se aproxima mais de um padrão normal ou de um determinado padrão que corresponde a uma alteração patológica. Tudo o que pode ser digitalizado em tese pode servir de material de entrada para as redes neurais: imagens, gravações de sons, sinais elétricos, textos e vídeos.

É relativamente fácil modelar, do ponto de vista teórico, uma rede neural, mas para a vermos entrar em ação e obtermos os resultados desejados, é preciso realizarmos o seu “treinamento”, o que requer uma grande quantidade de dados. Tal necessidade se satisfaz com o fato de que a produção mundial de informações vem crescendo exponencialmente, desde o surgimento da rede mundial de computadores. Aí estão incluídos dados

Figura 1. Representação visual da lei de Moore em escala semilogarítmica.


Apesar da necessidade de superação de diversas barreiras, o crescimento exponencial do número de transistores por microchip se mantém desde 1970. Fonte: Roser, Max; Ritchie, Hannah: Our World in Data. <https://ourworldindata.org/uploads/2020/11/Transistor-Count-over-time.png>. Traduzido para a língua portuguesa e reproduzido mediante licença “Creative Commons” CC BY 4.0 (<https://creativecommons.org/licenses/by/4.0/>).

demográficos, preferências individuais, hábitos, condições de saúde, resultados de pesquisas científicas e prontuários eletrônicos de milhões de pacientes. Portanto, os resultados obtidos hoje com as redes neurais só foram possíveis com o surgimento do fenômeno do “big data”. Essa expressão, que pode ser traduzida livremente como “dados em grande escala”, significa simplesmente uma quantidade de informações grande demais para ser processada em uma única máquina, utilizando-se métodos e algoritmos tradicionais; o seu processamento, classificação e análise estariam, portanto, necessariamente atrelados a um sistema de distribuição e cooperação entre diversos computadores conectados, via de regra, por uma rede local ou mesmo pela internet.⁵

Algumas Aplicações da Inteligência Artificial na Cardiologia já em Exploração


Interpretação do Eletrocardiograma

A aplicabilidade da inteligência artificial perpassa inúmeros segmentos da medicina e vem sendo usada para facilitar a interpretação de um dos exames complementares mais importantes da cardiologia, o eletrocardiograma (ECG). A interpretação (ou leitura) do eletrocardiograma exige extenso conhecimento técnico; mesmo assim, já são utilizados algoritmos próprios de máquinas para laudos automatizados, os quais, entretanto, interpretam diretamente os sinais elétricos obtidos e, inclusive, muitas

Figura 2. Modelagem computacional de um neurônio (neurônio artificial único).


As entradas são ponderadas e somadas, e adicionadas a um viés. A operação matemática inicial é um produto escalar (“dot product”) entre o vetor $[x_1, x_2, x_3, \dots]$ de entradas e o vetor $[w_1, w_2, w_3, \dots]$ de pesos. O resultado é adicionado ao viés (usualmente representado pela letra b , de “bias”, em inglês) e em seguida passado como argumento da função de ativação (em problemas de classificação, normalmente uma função que produz, para entradas ao longo de todo o seu domínio, uma curva suave entre os valores 0 e 1). O resultado final, nesse caso um número entre 0 e 1, pode ser passado como entrada para a próxima camada de uma rede neural artificial. Algumas vezes, as entradas são submetidas a um processo de filtragem ou preparo matematicamente chamado de “convolução”, e por isto as redes neurais que utilizam este método são também chamadas de “redes neurais convolucionais”. O processo de treinamento da rede neural envolve encontrar o conjunto de pesos e vieses ótimos para cada neurônio, ao longo de toda a rede.

Fonte: Autores.

Figura 3. Analogia do neurônio artificial com a célula neuronal biológica.

Fonte: https://commons.wikimedia.org/wiki/User:Lokal_Profil (modificado de forma autorizada, conforme licença “Creative Commons” CC BY-SA 3.0 (<https://creativecommons.org/licenses/by-sa/3.0/>)).

Figura 4. Representação esquemática de uma rede neural artificial. Cada círculo é um neurônio artificial e executa todas as operações matemáticas (Figura 2).



À medida que o tamanho da rede neural aumenta, a sua complexidade computacional cresce rapidamente, sendo impossível ao cérebro humano compreender com total precisão o funcionamento de todas as camadas ocultas. As saídas, que são números entre 0 e 1, via de regra, correspondem a probabilidades (por exemplo, “normal” ou “alterado”). O termo aprendizado “profundo” de máquina se refere simplesmente à utilização de mais de uma camada oculta de neurônios.

Fonte: https://commons.wikimedia.org/wiki/Artificial_neural_network#/media/File:Multi-Layer_Neural_Network-Vector.svg. Imagem em domínio público.

vezes carecem de precisão, bem como são pouco reprodutíveis. Hoje, já é explorado o reconhecimento de imagens digitalizadas do eletrocardiograma por redes neurais convolucionais, conseguindo-se bom grau de precisão no diagnóstico de algumas alterações eletrocardiográficas, o que pode contribuir diretamente para o manejo clínico dos pacientes.⁶ Nesse sentido, através de representações visuais digitais e análise de ECG de 12 derivações publicados no repositório PhysioNet, Das (2023) e colaboradores treinaram o modelo MobileNet V3 para o reconhecimento de 7 diagnósticos comuns na prática cardiológica: fibrilação atrial, bloqueio atrioventricular do primeiro grau, bloqueio de ramo esquerdo, bloqueio de ramo direito, além de alterações do segmento ST, sejam do tipo elevação ou depressão. Utilizando-se gravações com alta resolução (800 x 800 pixels),

foram produzidas 22.194 imagens, as quais, após processamento, geraram padrões classificáveis entre os 7 diagnósticos supracitados, atingindo precisão de até 91%, no caso da fibrilação atrial. Percebe-se, pois, benefício do método, obtendo-se boa reprodutibilidade, diante de maior facilidade de obtenção de imagem, maior disponibilidade e generalização do método, além da possibilidade de utilizar-se a técnica com imagens armazenadas em prontuário, o que não era factível com algoritmos de laudo automático anteriores, que interpretavam diretamente o sinal elétrico. Note que neste estudo, não se trata da interpretação automatizada do eletrocardiograma a partir do sinal produzido por aparelhos dedicados, como hoje é comum, mas a interpretação de traçados físicos amplamente disponíveis. Apesar de haver limitações, como o reduzido número de diagnósticos incluídos no estudo (Das, 2023), além da necessidade de

alto poder computacional para inclusão de maior número de parâmetros treináveis, a interpretação do ECG por reconhecimento de imagem tem muito potencial a ser explorado, de modo a se aproximar cada vez mais da forma humana de interpretação do traçado.

Deteção de Fibrilação Atrial e Outras Arritmias por Wearables

Um dos fatores que pode aumentar a utilidade de um procedimento diagnóstico é a sua disponibilidade. A utilização de *smartwatches* por razão de adesão à tecnologia e à “moda” tem aumentado muito nos últimos anos. Diversos estudos tem surgido para tentar determinar a utilidade desses dispositivos no diagnóstico da fibrilação atrial, arritmia muito comum e por vezes assintomática, mas com graves implicações nos riscos à saúde, sobretudo de acidente vascular cerebral. O reverso da medalha seria que a utilização indiscriminada de tais dispositivos amplamente disponíveis poderia levar ao sobrediagnóstico (*overdiagnosis*) e sobretestagem (*overtesting*), gerando custos e a inconveniência de procedimentos adicionais realizados, possivelmente desnecessários. Diversos estudos têm surgido para determinar o real papel e utilidade desses dispositivos na detecção precoce da fibrilação atrial. Alguns desses estudos têm sido inclusive custeados pela indústria da tecnologia (fabricantes de *wearables*), o que pode evidentemente levar a conflitos de interesses. Perez e colaboradores (2019) recrutaram 419.297 participantes para participar de um estudo sobre fibrilação atrial detectada por um *smartwatch*. Uma pequena parcela (0,52%) teve, durante o uso normal do dispositivo, uma notificação de pulso irregular, e a partir dessa informação, que foi enviada à central do estudo, recebeu em sua casa um *wearable* em forma de adesivo que registrava o eletrocardiograma (*ECG patch*), o qual era devolvido até sete dias de uso para análise. O valor preditivo positivo para a presença de fibrilação atrial foi alto, quando da recorrência da irregularidade de pulso, chegando a

84%. Uma grande parte dos pacientes, porém, não apresentou recorrência da irregularidade, por isso a prevalência geral de fibrilação atrial nos *ECG Patches* retornados foi de apenas 34%.⁷ Como resultado deste estudo, um total de 404 novos casos de fibrilação atrial foram diagnosticados, levando a tratamento médico. Um outro estudo (Dörr, 2019) semelhante, encontrou sensibilidade de 93,7%, especificidade de 98,2%, e acurácia de 96,1% para a detecção de fibrilação atrial utilizando um dispositivo semelhante.⁸

Deteção de Fibrilação Atrial à Distância

Percebe-se que com o envelhecimento da população mundial, a fibrilação atrial (FA) torna-se um problema de saúde pública cada vez mais relevante. Pacientes que apresentam acidente vascular cerebral (AVC) decorrente de FA têm mais chances de cursar com recorrência, maiores sequelas e maior mortalidade. A FA pode ser paroxística e assintomática, sendo diagnosticada em muitos casos apenas após levar a um AVC.

O uso de anticoagulantes para prevenção de eventos embólicos por FA, quando indicado, só é recomendado após documentação formal da arritmia. Para isto, pode-se fazer uso desde um simples eletrocardiograma até um *looper* implantável. Como vimos acima, tornou-se também possível a documentação por meio de “*wearables*” (como *smartwatches*), distinguir a fibrilação atrial de um ritmo sinusal com boa performance.

Estes dispositivos realizam a identificação da arritmia por meio da técnica de fotopletismografia (*photoplethysmography* - PPG), com pulsos de onda através de seus sensores óticos. Para tal, o dispositivo deve ter contato com a pele do usuário. Uma técnica de fotopletismografia que não necessita de contato (fotopletismografia remota - rPPG) está sendo desenvolvida para detecção da frequência cardíaca. Esta medida é realizada por uma câmera que detecta discretos nuances de variação da cor da pele da face conforme o sangue chega à pele.⁹

Sun (2024) e colaboradores treinaram uma rede neural convolucional profunda (*deep convolutional neural network* - DCNN) para identificação de fibrilação atrial à distância, utilizando-se de gravações de vídeo, segmentadas em fragmentos de 30 segundos e 10 minutos.

O modelo DCNN foi capaz de distinguir se o ritmo de base do paciente era de FA ou sinusal, analisando uma amostra de gravação de 30 segundos, com uma sensibilidade de 95%, e uma especificidade de 87,3%. Quando avaliada a acurácia do modelo em relação ao tempo obtido de gravação, observou-se que a acurácia atingia um pico após 120 a 240 segundos de gravação.

A detecção de FA por meio de rPPG avaliada por algoritmos de *deep learning* alcançou alta precisão na detecção de FA em uma população com diversos padrões de ECG. No futuro, essa avaliação poderá ser realizada por uma câmera de vídeo comum, como a de um *smartphone*, por exemplo. Nesse sentido, é uma ferramenta promissora para triagem populacional de FA e monitorização cardíaca extra-hospitalar com boa relação custo-benefício, podendo ser um grande avanço na prevenção do AVC.

Cardio-Oncologia

Com o advento de novas terapias oncológicas, tornam-se evidentes os efeitos colaterais decorrentes do tratamento, com especial ênfase nas doenças cardiovasculares, que representam uma causa substancial de morbidade e mortalidade entre os pacientes sobreviventes ao câncer. Neste cenário, a inteligência artificial pode vir a representar um papel crucial na identificação, diagnóstico, categorização, estratificação e gestão destas enfermidades, muito auxiliando na escolha dos tratamentos mais adequados, com alto grau de personalização (“*tailoring*”), ou apontando para interrupção ou mudança do esquema de tratamento, quando surgem sinais de cardiotoxicidade.

A aplicação da inteligência artificial nesta área emergente, a cardio-oncologia, visa a identificar indivíduos suscetíveis a complicações,

permitindo aos responsáveis pelo tratamento intervir de forma direcionada para a prevenção. Um exemplo prático é a utilização de modelos de aprendizado profundo para precisamente delinear as estruturas cardiovasculares em tomografias computadorizadas, com o intuito de planejar a dosagem de radioterapia em tumores torácicos. Adicionalmente, há o emprego de inteligência artificial na previsão do risco de óbito por doença cardiovascular em pacientes com câncer.

Por meio dos algoritmos de aprendizagem das redes neurais artificiais, existe um vasto território a ser explorado pela inteligência artificial na cardio-oncologia, frequentemente superando os especialistas humanos, dadas as miríades de possibilidades de tratamentos e combinações entre as diferentes modalidades terapêuticas. Contudo, é imperativo não desconsiderar a humanização e a abordagem holística do paciente oncológico, valendo-se da inteligência artificial como um método suplementar no diagnóstico e tratamento das toxicidades cardíacas associadas ao câncer. Zheng (2023) e colaboradores recentemente delinearão as contribuições das máquinas na área da cardio-oncologia em um extenso artigo de revisão.¹⁰

Avaliação de Exames de Imagem

Diversos triunfos se têm obtido em muitas áreas da medicina com relação à avaliação de exames de imagem através de redes neurais convolucionais. Recentemente, foi publicado um estudo que avalia um modelo baseado em inteligência artificial para prever o nível de suporte ventilatório em pacientes acometidos por COVID-19, através da análise da tomografia computadorizada por uma rede neural.¹¹ Na cardiologia, desde a época da mera angiografia quantitativa estática automatizada (método que nunca ganhou aceitação universal fora do âmbito da pesquisa) tem havido muitos avanços. A chamada avaliação fisiológica invasiva da gravidade de obstruções coronárias (cujo método-modelo é o F.F.R. – reserva de fluxo fracionária, obtido de forma invasiva) tornou-se um importante método

auxiliar na tomada de decisão quanto ao tratamento intervencionista. Muita atenção tem sido dada aos sistemas de avaliação fisiológica não-invasiva, baseados seja na angiotomografia coronária (F.F.R. virtual) ou na cineangiocoronariografia (razão de fluxo quantitativa baseada na lei de Murray das bifurcações fractais – μ QFR). Os primeiros modelos de avaliação fisiológica baseados na angiotomografia coronária se fundamentavam em algoritmos determinísticos que aplicavam uma modelagem física da circulação coronária e conceitos da dinâmica dos fluidos para determinar as quedas de pressão ao longo dos vasos, segundo o seu formato físico. Por se tratar de um algoritmo determinístico, o tempo de computação exigido para cada caso era de até 72 horas, o que foi reduzido para 12 a 24 horas com o uso de supercomputador compartilhado, o que, ainda assim, praticamente inviabilizaria a utilização do método para fins clínicos no dia-a-dia do laboratório de hemodinâmica.¹² Novos modelos envolvem a utilização de um sistema simplificado para a angiotomografia, reduzindo o tempo de computação para 4 minutos, e uma rede neural convolucional para a cineangiocoronariografia, com performance em tempo inferior a 20 minutos. Têm despertado muito interesse os métodos derivados de uma única sequência da cineangiocoronariografia, baseados na detecção de contornos, dimensões e tempo de enchimento do vaso. A ocorrência de bifurcações é computada segundo a lei de Murray das bifurcações fractais.¹³ Inicialmente, eram utilizadas duas ou três projeções para análise das lesões, mas depois verificou-se que se pode chegar a uma boa estimativa da repercussão funcional de estenoses utilizando-se apenas uma projeção.¹⁴ O tempo de computação utilizando equipamento amplamente disponível é aceitável, e uma versão comercial deste protocolo já está disponível para aquisição por serviços em regime de assinatura. Tanto a acurácia quanto o valor preditivo positivo do método ficaram em torno de 90%, quando comparados com o F.F.R. invasivo, considerado padrão-ouro para fins de estudo.

Conclusão e Perspectivas Futuras

Muito do que há cinco anos chamaríamos de “perspectiva futura”, hoje, já é plena realidade. Entretanto, é possível apontar algumas possíveis tendências que já chegam ao mundo da computação e da medicina, e pelo que tudo indica, passarão a fazer parte cada vez mais corriqueira da nossa vida pessoal e profissional. A Lei de Moore, que prevê que a capacidade de processamento dobra a cada dois anos, mantém-se vigente, embora tenha sofrido uma pequena desaceleração desde 2010 (desde então, vimos dobrar a capacidade de processamento a cada dois anos e meio, aproximadamente).¹⁵ Some-se a isto o fato de que costumamos superestimar o que pode acontecer em cinco anos e subestimar o que vai acontecer em vinte.

Uma forte tendência no mundo da computação é a chamada “computação ubíqua”. Conceitos relacionados seriam os de “computação transparente”, “pervasiva” ou “persuasiva”. Tal conceito refere-se ao ato de interagir com computadores sem que haja uma clara consciência do usuário, de que está interagindo com uma máquina, ou em lugares onde isto não seria esperado. Citamos, por exemplo, os “*wearables*”, hoje já utilizados para auxiliar no diagnóstico da fibrilação atrial e das arritmias. Estudam-se também sistemas para detecção precoce de alterações do segmento ST por *smartwatches*, apostando os entusiastas de que isto pode levar a um atendimento hospitalar mais precoce das síndromes coronárias agudas, salvando vidas.¹⁶ Tais dispositivos levam o conceito de “convergência digital” ao mais alto nível, não se podendo ainda saber os reais limites destas tecnologias.

Os aplicativos de “checagem de sintomas” trazem uma outra perspectiva, já disponíveis em plataformas comerciais de distribuição. Tais aplicativos procuram trazer a experiência de realizar uma consulta médica simplificada com uma inteligência artificial, totalmente online. Coleta-se uma história clínica sucinta, orienta-se procurar um serviço de pronto-atendimento em

caso de urgência e, ademais, fornecem informações sobre possíveis diagnósticos e quais seriam os exames complementares de maior utilidade. Um recente estudo (You, 2020) avaliou tais aplicativos, estabelecendo importantes fraquezas ainda presentes neste sistema. As principais fraquezas são a falha em avaliar apropriadamente o histórico médico pregresso dos pacientes, ter interface pouco flexível e perguntas de sondagem ainda muito problemáticas. Pode-se concluir que tais sistemas ainda se encontram em uma fase muito incipiente do seu desenvolvimento, ainda possuindo sérias desvantagens e não podendo substituir uma consulta médica presencial.¹⁷

Uma outra maneira de interação com as máquinas com a qual estaremos possivelmente envolvidos dentro em breve, seria a utilização por profissionais de saúde de sistemas generativos para registro automatizado da história clínica e do exame físico do paciente, com sistema de ativação por voz durante a consulta. Tal sistema está sendo chamado de “consulta médica auxiliada por inteligência artificial”. No futuro, sem dúvida, a inteligência artificial também ajudará a apontar possíveis diagnósticos e sugerir a realização dos exames complementares e tratamentos mais úteis, sendo que a diferença de tudo isto ocorre durante uma consulta médica “padrão”, presencial, com um médico humano.¹⁸ Tais sistemas merecem alguma consideração, pelas possíveis vantagens facilmente percebidas, sobretudo onde haja um número reduzido de médicos especialistas. Não são, entretanto, isentos de risco, como possivelmente o “*overdiagnosis*” e a interferência com o raciocínio clínico padronizado, podendo induzir ao erro. Isto, sem mencionar a possível exploração do conceito por razões puramente mercadológicas, fato eticamente relevante.

Falando-se de futuro, não poderíamos deixar de mencionar ainda a computação quântica. O conceito de “*Quantum Machine Learning*”, aplicado à medicina, já desponta como área muito promissora em um breve porvir. A computação quântica é notável por transformar problemas praticamente incomputáveis, como por exemplo

a decomposição de grandes números em fatores primos, em problemas facilmente solucionáveis, através das propriedades dos bits quânticos – “*qubits*”, a saber: superposição, entrelaçamento (ou “emaranhamento”), interferência e colapso após medição ou observação. De modo intuitivo e excessivamente simplificado, é como se essas propriedades permitissem o cálculo de diversas possibilidades matemáticas ao mesmo tempo, havendo com a medição o colapso “automático” para a solução correta. Na verdade, este mecanismo depende de algoritmos muito engenhosos, que utilizam as propriedades acima. Um algoritmo quântico (algoritmo de Shor) já está disponível para a fatoração de grandes números inteiros,¹⁹ podendo no futuro tornar inúteis os métodos de criptografia hoje amplamente utilizados. Quase toda a criptografia com a qual nossos dados trafegam via internet se baseia na propriedade matemática de que é impossível fatorar grandes números inteiros facilmente. O algoritmo de Shor, em um computador quântico com suficientes *qubits*, torna essa computação uma questão de meros minutos. Por enquanto, os nossos dados criptografados permanecem seguros, pois não há computadores quânticos amplamente disponíveis com *qubits* suficientes que tornem factível na prática essa quebra da criptografia. Entretanto, em um futuro próximo, isto fatalmente acontecerá. Fala-se que nem mesmo o jogo de xadrez está isento de uma possível completa solução rigorosa, graças aos computadores quânticos. Possíveis aplicações na medicina e, portanto, na cardiologia, para a computação quântica são a pesquisa genômica, simulações de interações entre moléculas para ajudar na escolha de tratamentos, e também a escolha de moléculas candidatas para novos medicamentos. Tais simulações envolvem um número proibitivo de computações pelos métodos tradicionais. Quiçá em um futuro não muito distante, possamos, com computadores quânticos, voltar a pensar em viabilizar o desenvolvimento de algoritmos determinísticos para diagnóstico e tratamento, baseados na regra de Bayes, mas agora com a força da computação quântica e do *big data*.

Há relativamente pouco tempo os motoristas de caminhão do mundo inteiro sentiam-se privilegiados, por acreditarem estar livres da “ameaça das máquinas”, na sua atuação profissional, ao contrário de muitas outras profissões, as quais já vêm testemunhando desemprego em massa devido à substituição por robôs e computadores. Hoje, os veículos autônomos já são uma realidade, para o transporte de bens e pessoas, inclusive com maior eficiência e redução do índice de acidentes (basta imaginar um motorista que não bebe, não dorme, nunca se sente cansado, doente ou indisposto, e respeita todas as leis de trânsito). A boa notícia é que a evolução destrói empregos em algumas áreas, mas cria em outras. Na área da saúde, seja assistencial ou na pesquisa, a boa prática dos cuidados tece o seu fundamento não só sobre a ciência, mas também sobre a ética, e uma firme aliança terapêutica entre seres humanos: profissionais, pacientes e familiares. Ninguém é, isoladamente, insubstituível, mas essa relação de confiança e solidariedade é muito difícil de ser reproduzida pelas máquinas. Tudo isto posto, é provável que os médicos, em especial os cardiologistas, não devam ser totalmente substituídos pelas inteligências artificiais em um futuro próximo previsível. Tal afirmativa deve, entretanto, ser encarada com uma pitada de cautela, pois como já foi dito, no mundo digital tendemos a superestimar o que pode acontecer em cinco anos, mas a subestimar o que realmente acontecerá em vinte.

Referências

1. Copeland, BJ (Ed.) The Essential Turing: the ideas that gave birth to the computer age. Oxford, Reino Unido: Clarendon Press, 2004. ISBN 0-19-825079-7.
2. McCarthy J, Minsky M, Rochester N, Shannon CE. A proposal for the Dartmouth Summer Research Project on artificial intelligence”. Disponível em: <http://raysolomonoff.com/dartmouth/boxa/dart564props.pdf> Agosto, 1955. [Acesso em 19/12/2023].
3. Joyce J. Bayes' Theorem. The Stanford Encyclopedia of Philosophy (Edição de Outono de 2021), Edward N. Zalta (ed.). Disponível em: <https://plato.stanford.edu/archives/fall2021/entries/bayes-theorem/> [Acesso em 19/12/2023].
4. Cooper GF. The computational complexity of probabilistic inference using bayesian belief networks. Artif Intell. 1990 Mar;42(2-3):393-405.
5. Lubanovic B. Introducing Python. Sebastopol, Califórnia, Estados Unidos da América: O'Reilly Media, Inc. ISBN: 9781492051367.
6. Das S, Epland M, Yu J, Suri R. Interpretation of EKG with Image Recognition and Convolutional Neural Networks. Curr Probl Cardiol. 2023 Aug;48(8):101744.
7. Perez MV, Mahaffey KW, Hedlin H, Rumsfeld JS, Garcia A, Ferris T et al. Large-scale assessment of a smartwatch to identify atrial fibrillation. New England Journal of Medicine 2019 Nov14;381(20):1909-17.
8. Dörr M, Nohturfft V, Brasier N et al. The WATCH AF Trial: SmartWATCHes for detection of atrial fibrillation. JACC Clin Electrophysiol. 2019 Feb;5(2):199-208.
9. Sun Y, Yang YY, Wu BJ, Huang PW, Cheng SE, Wu BF et al. Contactless facial video recording with deep learning models for the detection of atrial fibrillation. Sci Rep. 2022 Jan 7;12(1):281.
10. Zheng Y, Chen Z, Huang S, Zhang N, Wang Y, Hong S et al. Machine learning in cardio-oncology: new insights from an emerging discipline. Rev Cardiovasc Med. 2023 Oct 19;24(10):296.
11. Farahat IS, Sharafeldeen A, Ghazal M et al. An AI-based novel system for predicting respiratory support in COVID-19 patients through CT imaging analysis. Sci Rep. 2024 Jan 8;14(1):851.
12. Morris PD, van de Vosse FN, Lawford P V, Hose DR, Gunn JP. Virtual (computed) fractional flow reserve. JACC Cardiovasc Interv. 2015 Jul;8(8):1009-17.
13. Wikipedia. Murray's law. Disponível em: https://en.wikipedia.org/wiki/Murray%27s_law. Acesso em 09/01/2024.
14. Ding D, Tu S, Chang Y, Li C, Xu B, Wijns W. Quantitative flow ratio based on Murray fractal law: accuracy of single *versus* two angiographic views. Journal of the Society for Cardiovascular Angiography & Interventions. 2022 Sep;1(5):100399.
15. Wikipedia. Moore's Law. Disponível em: https://en.wikipedia.org/wiki/Moore%27s_law. Acesso em 31/12/2023.
16. Spaccarotella CAM, Polimeni A, Migliarino S, Principe E, Curcio A, Mongiardo A et al. Multichannel electrocardiograms obtained by a smartwatch for the diagnosis of ST-segment changes. JAMA Cardiol. 2020 Oct 1;5(10):1176.
17. You Y, Gui X. Self-diagnosis through AI-enabled chatbot-based symptom checkers: user experiences and design considerations. AMIA Annu Symp Proc. 2020;2020:1354-63.
18. Coombs B. I had a doctor's visit powered by A.I. – here's what it was like. Disponível em: <https://www.cnbc.com/2023/08/07/heres-what-ai-powered-doctors-visits-are-like.html>. [Acesso em 2/01/2024].
19. Wikipedia. Algoritmo de Shor. Disponível em: https://pt.wikipedia.org/wiki/Algoritmo_de_Shor. Acesso em 10/01/2024.