

APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL NO DIAGNÓSTICO POR IMAGEM

Data de aceite: 02/06/2023

Karen Sampaio Tomas

Discente do Curso de Biomedicina das Faculdades Integradas de Bauru – FIB

RESUMO: A inteligência artificial (IA) é a inteligência similar à humana desencadeada por *softwares*. Trata-se de um conjunto de modelos matemáticos complexos baseados na estrutura e no funcionamento de neurônios biológicos. O presente trabalho tem como objetivo apresentar, com base na literatura científica, os fundamentos bem como as aplicações da IA no diagnóstico por imagem. Dentre as diferentes ferramentas da IA com potencial no auxílio diagnóstico por imagem, destaca-se o diagnóstico auxiliado por computador (CAD) e a rede neural convolucional (CNN). O CAD é um sistema computacional que utiliza resultados de análises quantitativas automatizadas de imagens radiográficas registradas em banco de dados. A utilização do CAD tem como finalidade verificar a interpretação do radiologista e melhorar a acurácia do diagnóstico por imagem, mediante o uso da resposta do computador como referência. Como contribuições dessa ferramenta, pode-se citar o auxílio ao processamento

de imagens por meio de um sistema computacional contendo um banco de dados com padrões considerados normais e anormais. Já as CNNs são capazes de identificar moléculas com potencial no tratamento do câncer e interpretar imagens de tomografia computadorizada utilizando uma base de dados mundial de imagens associadas a termos típicos de diagnóstico. A utilização da IA como auxílio diagnóstico tem como objetivo propor um sistema que possa ser implementado nos exames de imagens tradicionais. Embora ainda incipiente, a expectativa é que vivenciaremos avanços na área do diagnóstico por imagem à medida que novos algoritmos de IA forem desenvolvidos para esse fim.

PALAVRAS-CHAVE: Inteligência artificial; Diagnóstico por imagem; Algoritmos; Aprendizagem profunda.

APPLICATION OF ARTIFICIAL INTELLIGENCE TO THE DIAGNOSTIC IMAGING

ABSTRACT: Artificial intelligence (AI) is a human-like intelligence triggered by software. It is a set of complex mathematical models based on the structure and functioning of biological neurons. This paper

aims to present, based on scientific literature, the fundamentals as well as applications of AI in imaging diagnosis. Among the different AI tools, with imaging diagnostic potential, computer-assisted diagnosis (CAD) and a convolutional neural network (CNN). CAD is a computer system that uses automated quantitative analysis results of radiographic images recorded in a database. The use of CAD as a use can verify radiologist interpretation and improve the accuracy of diagnostic imaging using the computer response as a reference. As contributions of this tool, one can cite or assist in the processing of images through a computer system including a database with patterns considered normal and abnormal. Since CNNs are able to identify molecules with potential for cancer treatment and interpret computed tomography images, using a worldwide database of images related to typical diagnostic terms. The use of AI as a diagnostic aid aims at a system that can be implemented in traditional imaging exams. Although still incipient, it is expected that advances in imaging diagnostics will be able to measure the latest AI algorithms for this purpose.

KEYWORDS: Artificial intelligence; Diagnostic imaging; Algorithms; Deep learning.

INTRODUÇÃO

A inteligência artificial (IA) é a inteligência similar à humana desencadeada por softwares. Trata-se de um conjunto de modelos matemáticos complexos baseados na estrutura e no funcionamento de neurônios biológicos e constituem ferramentas capazes de gerar modelos baseados em sistemas biológicos com confirmação estatística, e não em previsões não embasadas (ABBOD *et al.* 2007).

Para tanto, a IA utiliza não apenas conhecimentos da computação, mas também da biologia, engenharias, estatística, filosofia, física, linguística, matemática, medicina e psicologia. É um campo recente da ciência, com início datado em 1956, quando a tecnologia era muito limitada devido à inexistência de computadores capazes de processar a quantidade similar aos dados permitidos a partir da evolução das redes neurais artificiais. Por sua vez, as redes neurais artificiais (RNA) são sistemas que processam informações por interconexões entre unidades simples de processamento, denominadas de neurônios artificiais. Estes, por sua vez, são originados a partir de modelo matemático de um neurônio biológico (ALVAREZ *et al.* 2003). Atualmente, com o avanço tecnológico, é possível que os computadores sejam capazes de armazenar, processar e conseqüentemente de serem aplicados em diversas áreas como por exemplo, o da saúde e da segurança cibernética. Assim, cientistas investem na criação de dispositivos capazes de simular a capacidade humana de raciocinar, tomar decisões e de solucionar problemas (TUNES, 2019).

Uma das aplicações da IA está na melhoria dos serviços de diagnóstico por imagem. Técnicas como raio-X, tomografia computadorizada (TC), mamografia, ultrassonografia, densitometria óssea e ressonância magnética (RM) são utilizadas de acordo com a suspeita clínica do médico e são ferramentas importantes para o diagnóstico e determinação do prognóstico de diversas patologias (AZEVEDO-MARQUES, 2001).

Além dos exames por imagem apresentarem diferenças relacionadas ao aspecto

clínico, estes também diferem sob o princípio físico. Nesse contexto, ambos radiografia convencional e TC utilizam radiação ionizante para a formação da imagem. No entanto, o raio-X é ideal para a detecção de fraturas ósseas enquanto a TC proporciona maior detalhamento das imagens, sendo útil na identificação de áreas de hemorragias encefálicas, tumores, cistos, fraturas, derrames, entre outras coisas. A mamografia compartilha do princípio da radiação ionizante, porém é utilizada apenas para diagnóstico de neoplasias das mamas. Já a ultrassonografia é um exame não invasivo que fornece informações sobre a arquitetura interna de órgãos, sem a utilização de radiação e sim por meio de ondas de som de alta frequência. Essas ondas são transmitidas pelo transdutor para o interior do corpo, sendo absorvidas e refletidas em diferentes graus e captadas novamente pelo transdutor e exibidas no aparelho (AUGUSTO *et al.* 2000). Além disso, a densitometria óssea é um método de diagnóstico por Imagem que determina a densidade mineral óssea de regiões anatômicas do paciente permitindo o diagnóstico de doenças ósseas metabólicas e endócrinas que envolvem alterações no metabolismo dos sais inorgânicos cálcio e fósforo no corpo humano (DENADAI *et al.* 1998).

Enquanto a radiografia convencional projeta em um só plano todas as estruturas atravessadas pelos raios-X, a TC permite a reprodução do corpo humano em fatias ou cortes axiais e em vários planos, sendo possível a reconstrução das imagens nos planos sagital, coronal, além de reconstruções 2D ou 3D por meio de softwares. Assim, a TC evidencia as relações estruturais em profundidade, mostrando imagens do corpo humano em fatias, possibilitando a visualização de todas as estruturas em camadas e em alta definição. Entretanto, pelo fato de ser composta por muitas imagens, a demanda de tempo para a conclusão do exame é muito maior, o que gera sobrecarga de trabalho, condição que aumenta significativamente a ocorrência de falhas humanas no processo (NÓBREGA, 2016). Assim, a redução das falhas humanas pode ser implementada pelo diagnóstico auxiliado por computador (CAD). Esta compreende uma técnica de IA que utiliza o reconhecimento de padrões e assim faz um destaque em suspeitas de anormalidades, permitindo ao profissional radiologista revisar o exame e o interpretar corretamente (KATZEN *et al.* 2018). Outra aplicação da IA compreende o telediagnóstico, o qual possibilita o diagnóstico pelo médico a partir de imagens captadas pelos técnicos radiologistas ou à distância, o que além de otimizar o tempo, viabiliza o atendimento médico em pacientes que vivem em áreas onde os serviços de diagnóstico por imagem são precários. Assim, o sistema de telediagnóstico auxiliado por computador TCAD (Computer-Supported Telediagnosis), ou Tele-CAD, permite o acesso de pessoas ao atendimento médico adequado para regiões carentes de infraestrutura e possibilita o compartilhamento de recursos médicos entre unidades usuárias, fazendo com que os fatores restritivos que distanciam os pacientes de um atendimento médico de qualidade supere barreiras geográficas, temporais e socioeconômicas. Além disso, o TCAD é capaz de diminuir o custo de equipamentos e softwares, como também simplificar sua operação, manutenção e suporte (NÓBREGA,

2016).

Em concordância com a evolução no campo do diagnóstico por imagem bem como a necessidade de capacitação dos profissionais na área incluindo médicos radiologistas e biomédicos especialistas em diagnóstico por imagem, o entendimento das contribuições da IA nessa área é de extrema importância. Assim, o presente trabalho tem como objetivo apresentar os fundamentos bem como as diferentes aplicações da IA no diagnóstico por imagem.

MATERIAIS E MÉTODOS

Foi realizado um estudo teórico de revisão bibliográfica realizada entre julho de 2018 e novembro de 2019. Para tanto, foram utilizadas as palavras de busca *inteligência artificial*, *diagnóstico auxiliado por computador*, *aplicação da IA no diagnóstico por imagem*, *aprendizagem de máquina* e *aprendizagem profunda*. As bases de dados exploradas foram SCIELO, PubMed, Google acadêmico e revistas acadêmicas. Não foi aplicado nenhum critério de exclusão.

RESULTADOS E DISCUSSÃO

A IA pode ser aplicada à medicina de várias maneiras, seja pela classificação binária, segmentação de imagens médicas, estimativa de medições contínuas, e automação de fluxo de trabalho (PARK *et al.* 2018). Nessa revisão serão exploradas metodologias baseadas em IA com aplicação para diferentes cenários clínicos de medicina com foco no diagnóstico a partir de imagens.

As RNA têm sido campo de grande motivação na pesquisa envolvendo a neurociência, mais especificamente da parte cerebral chamada córtex visual. Um neurônio biológico, quando recebe um estímulo visual, carrega essa informação até a retina, onde é enviado um sinal ou potencial de ação que percorre uma sequência de regiões do cérebro por meio de interconexões neuronais. Essa transmissão de sinal é um processo químico complexo, que envolve a liberação de neurotransmissores para fazer a comunicação entre os neurônios. Cada um desses neurônios identifica características específicas da imagem correspondente ao estímulo visual. Assim, os neurônios das regiões iniciais detectam formas geométricas simples na imagem como cantos e bordas, e os neurônios das regiões finais têm função de detectar formas gráficas mais complexas compostas por inúmeras formas gráficas simples detectadas em regiões anteriores (BEZERRA, 2016). Já uma RNA contém um sistema de neurônios artificiais, sendo que cada unidade realiza uma computação baseada nas demais unidades nas quais estas estão conectadas. Os neurônios artificiais são organizados em camadas consecutivas e as conexões entre eles são controladas por valores reais denominados pesos. A RNA mais simples contém uma

única camada, composta por um único neurônio, porém redes dessa natureza são bastante limitadas. Porém é possível construir redes mais complexas por meio de um procedimento de composição de blocos de computação organizados em camadas (BEZERRA, 2016)

As Figuras 1 e 2 ilustram esquematicamente os elementos da arquitetura mais comum de RN denominada de Rede Alimentada Adiante (*Feedforward Neural Network*). Nessa arquitetura, a rede forma um gráfico direcionado, no qual os vértices representam os neurônios, e as arestas representam os pesos das conexões. A camada que recebe os dados é chamada camada de entrada, e a que produz o resultado final da computação é chamada camada de saída. Entre as camadas de entrada e saída, pode haver uma sequência de L camadas, onde ocorre o processamento interno da rede. Cada elemento dessa sequência é chamado de camada oculta. Após o seu treinamento, a rede é capaz de realizar um mapeamento de vetores no espaço D -dimensional para vetores no espaço C -dimensional (BEZERRA, 2016).

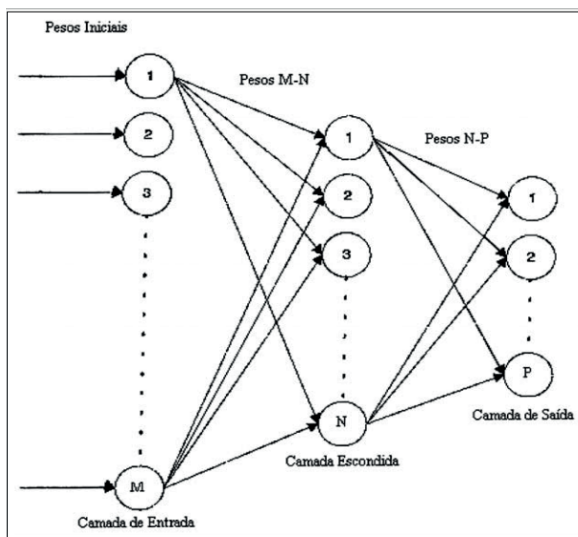



Figura 1: Representação esquemática da Rede Alimentada Adiante

Fonte: AZEVEDO-MARQUES, 2001.




Legenda: RNA com $(L + 1)$ camadas, sendo que há D unidades na camada de entrada e C unidades na saída. A l -ésima camada oculta contém $m^{(l)}$ unidades. Fonte: BEZERRA, 2016.

Figura 2: Representação matemática da Rede Alimentada Adiante

A utilização da IA é uma ferramenta que pode auxiliar no processamento de imagens, através de um sistema computacional contendo um banco de dados com padrões considerados normais e anormais. Assim, no momento do exame, o profissional pode ter a indicação mais fácil do padrão que está fora do normal, o que o levará a priorizar sua atenção para a realização do exame. Além disso, o sistema computacional permite um total manuseio 3D da imagem, possibilitando a adição de cores nas estruturas biológicas de acordo com suas densidades, e melhorando o detalhamento da imagem (AZEVEDO-MARQUES, 2001).

Dentre as diferentes ferramentas da IA com potencial no auxílio diagnóstico por imagem, destaca-se o diagnóstico auxiliado por computador (“*computer-aided-dianosis*” - CAD) e a rede neural convolucional (“*convolutional neural network*” - CNN). O diagnóstico auxiliado por computador pode ser definido como um diagnóstico que utiliza o resultado de análises quantitativas automatizadas de imagens radiográficas registradas em banco de dados. A utilização do CAD tem como finalidade verificar a interpretação do radiologista e melhorar a acurácia do diagnóstico por imagem, mediante o uso da resposta do computador como referência (AZEVEDO-MARQUES, 2001). É importante ressaltar que o computador é utilizado apenas como uma ferramenta adicional de informações, sendo que o diagnóstico final será feito pelo profissional radiologista. O CAD vem sendo muito estudado para a detecção de lesões de mama e tórax e sua utilização permite uma imagem mais nítida, tornando visíveis as lesões e microcalcificações que não podem ser vistas por meio da mamografia convencional (AZEVEDO-MARQUES, 2001). Tal ferramenta se torna de grande utilidade uma vez que 30% a 50% dos casos de câncer de mama detectados por meio de mamografia apresentam agrupamentos de microcalcificações associados, e 26% dos casos de câncer não-palpável de mama apresentam nódulos associados na mamografia e

18% apresentam nódulos e microcalcificações (AZEVEDO-MARQUES, 2001).



Legenda: Mamografia digitalizada contendo agrupamento de microcalcificações suspeitas. A: região de interesse contendo um agrupamento suspeito de microcalcificações. B: Imagem após "stretch". C: Imagem-diferença. D: imagem segmentada. Fonte: (AZEVEDO-MARQUES, 2001).

Figura 3: Exemplo de segmentação de imagem

Na Figura 3, a imagem apresenta um método de segmentação *stretching* muito utilizado em processamento de imagens e tem por objetivo aumentar o contraste. A técnica de imagem-diferença é utilizada para o realce de microcalcificações e nódulos mediante supressão das estruturas de fundo da imagem, causadas pela anatomia normal da mama. Trata-se de um método de limiar ou *thresholding*, baseado em estatísticas dos valores de pixels, tendo por finalidade a representação binária da imagem (AZEVEDO-MARQUES, 2001).

No estudo de AZEVEDO-MARQUES (2001), a análise das imagens representadas na Figura 3 demonstrou uma sensibilidade de 98,3% para a detecção de agrupamentos de microcalcificações e 72% para a detecção de nódulos, com uma taxa de falso-positivo média de 1 agrupamento ou nódulo por imagem. Em outro estudo objetivando comparar a leitura de uma sequência de imagens utilizando o ImageChecker para a detecção de agrupamentos de microcalcificações e nódulos entre dois radiologistas e entre um radiologista e o sistema CAD, não foram observadas diferenças significativas, demonstrando a eficiência do sistema CAD (AZEVEDO-MARQUES, 2001).

O processamento da imagem é realizado para realce e segmentação das lesões, permitindo a subdivisão da imagem de acordo com características específicas. Após o realce e a segmentação, é possível adicionar atributos às imagens para quantificação, como tamanho, contraste e forma dos seus objetos constituintes, tornando possível a observação de lesões não compatíveis com a visão humana e possibilitando um diagnóstico mais preciso e confiável (AZEVEDO-MARQUES, 2001).


A IA envolve o uso do computador para o processamento de dados, visando a distinção entre padrões normais e anormais, a partir dos atributos extraídos das imagens. As técnicas relacionadas a essa área do conhecimento incluem métodos para a seleção de atributos, como aqueles baseados na separação entre as distribuições de probabilidades

das classes e algoritmos genéticos, e classificadores, como os baseados em técnicas de análise discriminante, sistemas especialistas baseados em regras específicas e métodos estatísticos RNA.

Os sistemas CAD utilizam de técnicas provenientes de duas áreas do conhecimento: visão computacional, que envolve o processamento de imagem para realce, segmentação e extração de atributos, e IA, que inclui métodos para seleção de atributos e reconhecimento de padrões. O CAD pode ser aplicado a todas as modalidades de obtenção de imagem, incluindo radiografia convencional, tomografia computadorizada, ressonância magnética, ultrassonografia e medicina nuclear. Também é possível desenvolver esquemas de CAD para todos os tipos de exame de todas as partes do corpo, como crânio, tórax, abdômen, osso e sistema vascular, entre outros (AZEVEDO-MARQUES, 2001).

A IA tem sido um campo ativo de pesquisa desde os anos 50, e atualmente, os algoritmos alcançaram desempenho sub-humanos sendo aplicados em diversas áreas da saúde como um auxílio diagnóstico, como a identificação de tumores metastáticos de origem desconhecida chamado de teste de origem tumoral (TOT), no diagnóstico de nódulos da tireoide indeterminados, o que pode reduzir em até 81% das cirurgias desnecessárias (TUNES, 2019).

A segmentação de imagem é um trabalho demorado e extenso, sendo uma fonte de possível erro humano. No entanto, a aplicação de IA por meio da rede neural convolucional (CNN, do inglês *Convolutional Neural network*) torna esse processo mais rápido e automático, cuja representação do processo de dados está mostrado na Figura 4. A CNN é uma aplicação que remove as barreiras que impedem a otimização de exames, com a redução de tempo e esforço durante a segmentação de imagens por TC por exemplo (MINNEMA *et al.* 2018).



Legenda: input layer: camada de entrada; hidden layer 1, 2 and 3: camada escondida; output layer: camada de saída. Linhas representam as conexões internas. Fonte: *Deep Learning Book* - Introdução às redes neurais convolucionais. Disponível em: <http://deeplearningbook.com.br/introducao-as-redes-neurais-convolucionais/>

Figura 4: Representação do processamento de dados nas CNNs

Estudos indicam que as CNNs são capazes de identificar moléculas com potencial no tratamento para câncer, bem como auxiliar no diagnóstico de forma rápida e precisa em pacientes que apresentam sintomas de doenças cardiovasculares avaliados por ressonância magnética. Além disso, é capaz de interpretar imagens de TC por exemplo, utilizando uma base de dados mundial de imagens associadas a termos típicos de diagnóstico. A CNN também permite a detecção precoce da retinopatia diabética, que é uma das maiores responsáveis pela cegueira, de tumores como por exemplo o melanoma (disponível pela IBM, *International Business Machines Corporation*), e de acompanhar de forma não invasiva a evolução de tumores (FLORINDO, 2019). A CNN aplicada na construção de imagens é feita com precisão e é considerada padrão-ouro em pacientes anteriormente submetidos à craniotomia e cranioplastia (MINNEMA *et al.* 2018).

A medicina é um dos campos mais beneficiados com a IA, que otimiza processos complexos e imperfeitos como o diagnóstico diferencial. Essa é uma área de domínio do *Machine Learning* (ML), que compreende uma área da ciência da computação que significa aprendizado da máquina (LUGO-REYES *et al.* 2014). Trata-se de uma ferramenta que está ganhando uma rápida importância na radiologia, pois permite a exploração de padrões em dados de imagens e registros de pacientes para uma quantificação, diagnóstico e prognóstico mais preciso (LANG, 2018). Junto com o ML, os métodos de IA são excelentes para reconhecer automaticamente padrões radiográficos complexos em dados de imagem e fornecer avaliações quantitativas, e não meramente qualitativas (HOSNY *et al.* 2018). Esse auxílio pode ser útil, uma vez que o diagnóstico do radiologista é baseado em uma avaliação subjetiva, estando sujeito a variação intra e interpessoais, bem como perda de informação devido à natureza sutil do achado radiológico, baixa qualidade da imagem, sobreposição de estruturas, fadiga visual ou até distração (AZEVEDO-MARQUES, 2001).

As aplicações do ML têm sido estudadas para aplicação em testes de função pulmonar. A ML utiliza modelos de CNN que permitem o reconhecimento de padrões obstrutivos na TC, responsável pelo diagnóstico diferencial de doenças obstrutivas pulmonares. Além disso, a utilização da ML oferece resultados precisos em diversos exames de TC pulmonar, como a função pulmonar obstrutiva, em testes de oscilação forçada, análise da respiração, análise do som pulmonar e telemedicina (DAS, 2017).

A IA e o ML influenciaram a medicina de várias formas. Nesse contexto, recentes avanços nos campos de IA e ML causaram grande impacto na análise de imagem nas áreas da microscopia a radiologia. Aprimoramentos em *hardware* computacional estão permitindo que pesquisadores revisem antigos algoritmos de inteligência artificial e experimentem novas ideias matemáticas. A aplicação destes métodos é muito ampla, podendo ser implantado desde a microscopia, para reconstrução de imagem tomográfica, bem como para o planejamento diagnóstico (MANDAL *et al.* 2018). Análises por citometria de fluxo multicolorida são utilizadas para identificar doença residual mínima de leucemia mieloide aguda e síndrome mielodisplásica após tratamento. No entanto, a interpretação manual

possui inconvenientes como a demanda de tempo e variações de interpretação. A IA, com a expertise em auxiliar análises repetitivas ou complexas, representa uma solução potencial para essas desvantagens. Os algoritmos de IA podem produzir análises de citometria de fluxo multicoloridas eficientes e clinicamente relevantes. Esta abordagem também possui uma grande vantagem na capacidade de integrar outros testes clínicos (KO *et al.* 2018).

A IA baseada em aprendizagem profunda (AP) tem sido algo de grande interesse global nos últimos anos. A AP tem sido amplamente adotada no reconhecimento de imagens, reconhecimento de fala e processamento de linguagem natural, mas está apenas começando a causar impacto nos serviços de saúde, pois ainda não é utilizada em rotina clínica (TING *et al.* 2018). AAP permite que modelos computacionais complexos processem várias camadas de processamento dando ênfase em diferentes níveis de abstração. Assim, revolucionou o conhecimento da fala, reconhecimento visual e a detecção de objetos e muitos outros domínios como descoberta de medicamentos e genômica. Além disso, a AP através da utilização de algoritmos de retropropagação indica como a máquina deve alterar seus parâmetros internos utilizados para calcular as representações em cada camada representação da camada interior. As CNN aplicadas em AP trouxeram avanços no processamento de imagens, vídeo, fala e áudio (BEZERRA, 2016).

AAP constitui uma subárea da ML, e ambas têm como objetivo simular o comportamento do cérebro humano, como o reconhecimento visual, da fala e o processamento de linguagem natural. Algoritmos de AP produzem representações de acordo com prioridades registradas nos dados de entrada, através de camadas de processamento sequencial em uma RNA (BEZERRA, 2016). Na área da oftalmologia, a AP tem sido aplicada em fotografias de fundo, tomografia de coerência óptica e campos visuais, obtendo desempenho robusto na detecção de retinopatia diabética e retinopatia da prematuridade, disco óptico semelhante ao glaucoma, edema macular e degeneração macular relacionada à idade. A identificação destas patologias com o uso de IA e AP são feitos da forma mais simples e rápida. A AP na imagem ocular pode ser usada em conjunto com a telemedicina como uma possível solução para rastrear, diagnosticar e monitorar as principais doenças oculares em pacientes na atenção primária e em ambientes comunitários. No entanto, também existem desafios potenciais com a aplicação da AP na oftalmologia, incluindo desafios clínicos e técnicos, explicabilidade dos resultados do algoritmo, problemas médico-legais e aceitação pelo médico e paciente dos algoritmos que podem trazer riscos de distorções (TING *et al.* 2018). Recentes estudos de algoritmos de IA estão em desenvolvimento para uso em triagens fotográficas de retinopatia diabética. Para ser clinicamente aceitável, esses sistemas também devem ser capazes de classificar outras anormalidades do fundo do olho e características clínicas no ponto de atendimento, não tendo a necessidade de aparelhos sofisticados. O desempenho se mostrou ser promissor, mas ainda não ao nível necessário para sua aplicação clínica (STEVENON *et al.* 2018).

A IA permite que as máquinas forneçam valor incomparável de informações em uma

infinidade de indústrias e aplicativos. Os pesquisadores têm utilizado a IA para analisar dados médicos não estruturados e de grande volume e para realizar tarefas clínicas, como a identificação de retinopatia diabética ou o diagnóstico de malignidades cutâneas. Aplicações de técnicas de IA, especificamente aprendizado de máquina e, mais recentemente, aprendizado profundo, estão começando a surgir na endoscopia gastrointestinal. O mais promissor desses esforços tem sido a detecção de pólipos colorretais assistida por computador e no diagnóstico auxiliado por computador. Esses sistemas demonstram alta sensibilidade e precisão, quando comparados a endoscopistas especialistas em humanos. A IA também tem sido utilizada para identificar sangramento gastrointestinal, detectar áreas de inflamação e até mesmo diagnosticar certas infecções gastrointestinais (ALAGAPPAN *et al.* 2018).

A imagem médica avalia o tumor e seu ambiente em sua totalidade, o que o torna adequado para monitorar as características temporais e espaciais do tumor. O progresso em métodos computacionais para o processo e análise de imagens médicas, especialmente os baseados em IA, converteu essas imagens em dados quantitativos e minuciosos associados a eventos clínicos no manejo oncológico. Com base em uma grande quantidade de imagens radiográficas e aplicação de IA e ML, os pesquisadores desenvolveram e validaram modelos radiômicos que podem melhorar a precisão de diagnósticos e avaliações de respostas terapêuticas (LIU *et al.* 2019). A TC possui diversas ferramentas que permitem fazer análises, tirar medidas, verificar densidade, medir lesões, hemorragias, cistos e tumores. Em situações mais específicas como no acidente vascular cerebral (AVC) ou hemorragia encefálica, a função “mapa/difusão” permite que o médico tenha uma visão nítida e detalhada da área atingida pelo extravasamento de sangue. Nos anos 70, os primeiros *scanners* de TC já usavam algoritmos de reconstrução iterativa, porém esse recurso não era aplicado na rotina clínica por deficiência das ferramentas computacionais. Apenas em 2009 que os primeiros algoritmos de reconstrução iterativa foram disponibilizados comercialmente para substituição da projeção convencional. Esta técnica desde então causou uma verdadeira evolução no campo da radiologia, e em poucos anos todos os principais fornecedores de TC introduziram algoritmos de reconstrução iterativa para rotina clínica, que evoluíram rapidamente para algoritmos de reconstrução cada vez mais avançados. A complexidade desses algoritmos varia de algoritmos híbridos, baseados em modelos algoritmos totalmente iterativos. A IA aumentará ainda mais o desempenho dos métodos de reconstrução (WILLEMINK *et al.* 2018).

Vários estudos têm sido realizados com o objetivo de validar os métodos estatísticos para verificação da performance das ferramentas em diagnóstico e predição. Nesse sentido, pesquisa foi conduzida para verificar algoritmo baseado em aprendizagem profunda desenvolvido para diferenciar câncer de pulmão (doença) de tumor benigno (não doença) em nódulos pulmonares em radiografia simples de tórax (PARK *et al.* 2018). Quando os resultados de um teste ou algoritmo de diagnóstico são binários, o desempenho

de discriminação é normalmente medido em termos de sensibilidade (proporção de teste positivo em indivíduos com doenças) e especificidade (proporção de indivíduos negativos em indivíduos que não têm doença). Mesmo que o algoritmo de aprendizagem profunda apresenta os resultados finais de maneira dicotômica (por exemplo maligno vs benigno), o algoritmo calcula internamente uma porcentagem (*output* contínuo) (Tabela 1), e depois aplica o limiar configurando o resultado final (Tabela 2). Portanto, dependendo dos níveis de limiar que são aplicados à porcentagem inicial, vários pares de valores de sensibilidade e especificidade são obtidos (Tabela 2). Assim, quando o limiar para o diagnóstico de pulmão o câncer é reduzido, a sensibilidade aumenta enquanto a especificidade diminui, e vice-versa (Tabela 2).

Contínuo output	Câncer	Doença benigna
0	0	5
0,1	2	103
0,2	6	90
0,3	5	21
0,4	5	8
0,5	8	5
0,6	15	8
0,7	20	5
0,8	25	4
0,9	11	1
1,0	3	0
Total	100 pacientes	250 pacientes

Legenda: Dados representam número de pacientes e contínuo *output* para a diferenciação de doença (câncer) e não doença (nódulos benignos) a partir de imagens de radiografias de tórax. Fonte: Adaptado de Park *et al.* 2018.

Tabela 1. Resultados obtidos a partir de um estudo hipotético para avaliação da *performance* do algoritmo baseado em aprendizado profundo.

Critério para diagnosticar câncer de pulmão	Sensibilidade (%)	Especificidade (%)	1 – Especificidade (%)
≥ 0,1	100	2	98
≥ 0,2	98	43,2	56,8
≥ 0,3	92	79,2	20,8
≥ 0,4	87	87,6	12,4
≥ 0,5	82	90,8	9,2
≥ 0,6	74	92,8	7,2
≥ 0,7	59	96	4
≥ 0,8	39	98	2
≥ 0,9	14	99,6	0,4
≥ 1,0	3	100	0

Legenda: os dados representam porcentagens calculadas a partir da aplicação de vários limiares aos resultados da Tabela 1. Fonte: Adaptado de Park *et al.* 2018.

Tabela 2. Sensibilidade e especificidade do algoritmo baseado em aprendizagem profunda para o diagnóstico de câncer de pulmão após aplicação do limiar

Um dos principais desafios da IA no campo do diagnóstico é na validação e na avaliação da performance dos mesmos, para que os resultados da IA sejam fidedignos em termos clínicos. Os termos *validação* se refere ao estágio de ajuste fino do desenvolvimento de modelo e *teste* refere-se ao processo de verificação do desempenho do mesmo. Uma vez que o desempenho de um modelo de diagnóstico é afetado pelo espectro de manifestação da doença, é necessário a confirmação clínica do desempenho de um diagnóstico baseado em IA. A verificação clínica do desempenho de uma ferramenta IA no auxílio diagnóstico requer validação clínica externa em uma população alvo de pacientes. Este procedimento é crucial para evitar superestimação do desempenho e de possíveis vieses de espectro. Assim, a melhor verificação clínica de um diagnóstico obtido a partir da IA requer uma demonstração de seu valor através de seu efeito nos resultados dos pacientes, além das métricas de desempenho, que podem ser alcançadas por meios de ensaios clínicos ou pesquisas observacionais.

CONCLUSÃO

O diagnóstico auxiliado por computador baseados em métodos de IA, AP e ML tem como objetivo propor um sistema que possa ser implementado em exames de imagens, permitindo que auxiliem os profissionais na determinação mais precisa das características patológicas. E assim, promover a eficiência dos exames de imagem, em termos de otimização temporal e do processo de análises. O desenvolvimento de algoritmos de IA ainda é incipiente, porém o avanço tecnológico e computacional promete uma revolução no diagnóstico por imagem e na medicina, além de demais áreas. Os desafios na exploração

do potencial da IA na medicina pode ser considerado circunstancial, os quais estão relacionados a comportamentos sociais da sociedade e intrínsecos bem como àqueles relacionados às capacidades da ciência e tecnologia subjacentes. Ambos devem ser resolvidos para que tanto a sociedade quanto à classe profissional seja grandemente beneficiada com a IA.

REFERÊNCIAS

ABBOD, M. F. *et al.* Application of artificial intelligence to the management of urological cancer. **Journal of Urology**, v. 178, n. 4 Pt 1, p. 1150–1164, oct. 2007.

ALAGAPPAN, M. *et al.* Artificial intelligence in gastrointestinal endoscopy: The future is almost here. **World Journal of Gastrointestinal Endoscopy**, v. 10, n. 10, p. 239-249, oct. 2018.

ALVAREZ, A. B. *et al.* **Rede Neural de Kohonen e Outras Técnicas para Treinamento Não-Supervisionado**. Faculdade de Engenharia Elétrica e Computação, Universidade Estadual de Campinas. 2003. 38f.

AUGUSTO, A. Q. *et al.* Princípios físicos da ultra-sonografia. **Arquivos de Ciências Veterinárias e Zoologia da UNIPAR**, v. 3, n. 1, p. 61-65, jan./jul. 2000. Disponível em: <https://revistas.unipar.br/index.php/veterinaria/article/view/689/597>. Acesso em: 02 oct. 2019.

AZEVEDO-MARQUES, P. M. Diagnóstico auxiliado por computador na radiologia. **Radiologia Brasileira**, v. 34, n. 5, p. 285-293, 2001. Disponível em: <http://www.scielo.br/pdf/rb/v34n5/7682.pdf>. Acesso em: 10 oct 2019.

BEZERRA, E. Introdução à aprendizagem profunda. In: **Tópicos em Gerenciamento de Dados e Informações**. Porto Alegre: Sociedade Brasileira de Computação, p. 57–86, 2016.

CARVALHO, A. P. História da tomografia computadorizada. **Revista da Imagem**, v. 29, n. 2, p. 61-66, abr./jun. 2007.

DAS, N. *et al.* Artificial intelligence in diagnosis of obstructive lung disease: current status and future potential. **Current Opinion in Pulmonary Medicine**, v. 24, n. 2, p. 117-123, mar. 2018.

DENADAI, R. C *et al.* Efeitos do exercício moderado e da orientação nutricional sobre a composição corporal de adolescentes obesos avaliados por densitometria óssea (DEXA). **Revista Paulista de Educação Física**, v. 12, n. 2, p. 210-218, jul./dez. 1998. Disponível em: <http://www.luzimarteixeira.com.br/wp-content/uploads/2011/02/efeito-do-exer-no-imc-pelo-dexa.pdf>. Acesso em: 02 set. 2019.

FLORINDO, J. B. **Redes Neurais Convolucionais - Deep Learning**. Instituto de Matemática, Estatística e Computação Científica, Universidade Estadual de Campinas. 2019. 70f. Disponível em: <https://www.ime.unicamp.br/~jbfiorindo/Teaching/2018/MT530/T10.pdf>. Acesso em 01 nov. 2019.

HOSNY, A. *et al.* Artificial intelligence in radiology. **Nature Reviews Cancer**, v. 18, n. 8, p. 500-510, aug. 2018.

KATZEN, J. A review of computer aided detection in mammography. **Clinical Imaging**, v. 52, n. 1, p. 305-309, nov./dec. 2018.

KO, B. S. *et al.* Clinically validated machine learning algorithm for detecting residual diseases with multicolor flow cytometry analysis in acute myeloid leukemia and myelodysplastic syndrome. **EBioMedicina**, v. 37, n. 1, p. 91-100, nov. 2018.

LANGS, S. *et al.* Machine learning: from radiomics to discovery and routine. **Radiologe**, v. 58, n. S1, p. 1-6, nov. 2018.

LIU, Z. *et al.* The Applications of Radiomics in Precision Diagnosis and Treatment of Oncology: Opportunities and Challenges. **Theranostics**, v. 9, n. 5, p. 1303-1322, feb. 2019.

LUGO-REYES, S. O. *et al.* Artificial intelligence to assist clinical diagnosis in medicine. **Revista Alergia Mexico**, v. 61, n. 2, p. 110-20, abr./jun. 2014.

MANDAL, S. *et al.* Imaging Intelligence: AI Is Transforming Medical Imaging Across the Imaging Spectrum. **IEEE Pulse**, v. 9, n. 5, p. 16–24, set. 2018.

MINNEMA, J. *et al.* CT image segmentation of bone for medical additive manufacturing using a convolutional neural network. **Computacional Biology and Medicine**, v. 103, n. 1, p. 130-139, dec. 2018.

NÓBREGA, G. A. S. D. **Telediagnóstico em imagens de tomografia computadorizada na indicação do tratamento de câncer de pulmão: uma abordagem baseada em inteligência artificial.** Tese (doutorado) - Engenharia elétrica – Centro de tecnologia, Universidade Federal do Rio Grande do Norte, Natal 2016. 56f. Disponível em: https://repositorio.ufrn.br/jspui/bitstream/123456789/21554/1/GiovaniAngeloSilvaDaNobrega_TESE.pdf. Acesso em: 15 oct 2019.

PARK, S. H. *et al.* Methodologic Guide for Evaluating Clinical Performance and Effect of Artificial Intelligence Technology for Medical Diagnosis and Prediction. **Radiology**, v. 286, n. 3, p. 800-809, mar. 2018.

STEVENSON, C. H. *et al.* Development of an artificial intelligence system to classify pathology and clinical features on retinal fundus images. **Clinical and Experimental Ophthalmology**, v. 47, n. 4, p. 484-489, mai. 2019.

TING, D. S. W. *et al.* Artificial intelligence and deep learning in ophthalmology. **British Journal of Ophthalmology**, v. 103, n. 2, p. 167-175, feb. 2019.

TUNES, S. Terreno fértil para inteligência artificial, **Revista FAPESP**, v. 275, n. 1, p. 18-29, 2019. Disponível em: <https://revistapesquisa.fapesp.br/2019/01/09/terreno-fertil-para-a-inteligencia-artificial/>. Acesso em: 10 set. 2019.

WILLEMINK, M. J. *et al.* The evolution of image reconstruction for CT-from filtered back projection to artificial intelligence. **European Radiology**, v. 29, n. 5, p. 2185-2195, mai. 2019.