

Uso de Redes Neurais para a Predição de Diagnóstico de AVE: Uma Revisão Sistemática

Use of Neural Networks for Stroke Diagnosis Prediction: A Systematic Review Neural Networks and Stroke Prediction

Vanessa de Oliveira e Silva¹, ORCID iD: <https://orcid.org/0000-0003-0417-9311>

Joana Karollyne de Siqueira Mendes¹, ORCID Id: <https://orcid.org/0000-0002-7321-3539>

Valter Augusto de Barros Filho¹, ORCID iD: <https://orcid.org/0000-0002-0277-2480>

Maria das Graças Loureiro das Chagas Campêlo², ORCID iD: <https://orcid.org/0000-0001-6579-6538>,

Eanes Torres Pereira³, ORCID iD: <https://orcid.org/0000-0002-9717-794X>

ABSTRACT

Background: Stroke is an acute neurological deficit syndrome attributed to vascular injury to the Nervous System (NS). Artificial Intelligence (AI) techniques in Medicine — such as Artificial Neural Networks (ANNs) algorithms — have helped in making clinical decisions aimed at this condition.

Objective: the objective of this review will be to evaluate how artificial neural networks are being used to predict the diagnosis of stroke.

Methods: This is a systematic review of articles indexed in PubMed, VHL, SciELO, Cochrane and SpringerLink databases, between January and February 2022. The inclusion criteria and filters for this work were: articles related to the topic, studies randomized, cohort and clinical trials, studies in humans, carried out in the last 5 years, only in Portuguese, English and Spanish and with full text available free of charge. The exclusion parameters were: duplicate articles, escape from the topic, review articles and works that did not meet all the inclusion criteria.

Results: ANNs are being used mainly for the evaluation of areas of ischemic and hemorrhagic lesions by segmentation methods and the most used exams for modeling the programs have been Magnetic Resonance Imaging (MRI) and Computed Tomography (CT). In addition to CT and MRI, magnetic resonance angiography and tomography angiography are also being used to model the algorithm and are useful because they have greater sensitivity for detecting infarctions.

Conclusion: Segmentation and classification algorithms applied in ANNs are part of personalized medicine and serve as a basis for physicians in clinical practice.

Keywords: Machine Learning, Stroke, Computational Neural Networks.

RESUMO

Fundamentos: O Acidente Vascular Encefálico (AVE) é uma síndrome de déficit neurológico agudo atribuído à lesão vascular do Sistema Nervoso (SN). As técnicas de Inteligência Artificial (IA) na Medicina — como algoritmos de Redes Neurais Artificiais (RNAs) — têm ajudado na tomada de decisões clínicas voltadas para essa condição.

Objetivo: o objetivo desta revisão será avaliar como as redes neurais artificiais estão sendo utilizadas para a predição de diagnóstico de AVE.

Métodos: Trata-se de uma revisão sistemática de artigos indexados nas bases de dados PubMed, BVS, SciELO, Cochrane e SpringerLink, entre janeiro e fevereiro de 2022. Os critérios de inclusão e filtros para esse trabalho foram: artigos relacionados ao tema, estudos randomizados, coorte e ensaios clínicos, trabalhos em humanos, realizados nos últimos 5 anos, apenas nos idiomas Português, Inglês e Espanhol e com texto completo disponível gratuitamente. Os parâmetros de exclusão foram: artigos duplicados, fuga ao tema, artigos de revisão e trabalhos que não preenchiam todos os critérios de inclusão.

Resultados: As RNAs estão sendo utilizadas, principalmente, para avaliação de áreas de lesões isquêmicas e hemorrágicas por métodos de segmentação e os exames mais utilizados para a modelagem dos programas têm sido Ressonância Magnética (RM) e Tomografia Computadorizada (TC). Além da TC e RM, a angiorressonância e angiotomografia também estão sendo utilizadas para o modelamento do algoritmo e são úteis por apresentarem maior sensibilidade para detecção de infartos.

Conclusão: Algoritmos de segmentação e classificação aplicados nas RNAs fazem parte da medicina personalizada e servem de base para médicos na prática clínica.

Palavras-chave: Aprendizagem de Máquina, Acidente Vascular Encefálico, Redes Neurais Computacionais.

¹Discentes do Curso de Medicina da Universidade Federal de Campina Grande (UFCG);

²Professora da Unidade Acadêmica de Medicina e Doutora em Ciências da Saúde,

³Professor da Unidade Acadêmica de Ciências da Computação e Doutor em Ciências da Computação.

Autor correspondente: Maria das Graças Loureiro das Chagas Campêlo, R. Carlos Chagas, s/n - São José, Campina Grande - PB, 58400-398, mgracasloureiro@gmail.com

Declaração e conflito de interesses: Todos os autores declaram que não há quaisquer conflitos de interesses.

Financiamento: Este artigo não foi financiado por nenhuma instituição.

INTRODUÇÃO

O Acidente Vascular Encefálico (AVE) é uma síndrome definida por déficit neurológico focal agudo atribuído a lesão vascular do sistema nervoso central, com sintomas que podem durar 24 horas ou mais causando alterações conforme a área acometida e a extensão da lesão^{1,2}. Em todo o mundo, o AVE é a principal causa de deficiência física adquirida em adultos e a segunda principal causa de mortalidade em países de renda média-alta^{1,3}. O AVE pode ser dividido em dois grupos: isquêmico e hemorrágico³. O AVE isquêmico pode ser subdividido em cinco grandes subtipos de acordo com a classificação da *Trial of Org in Acute Stroke Treatment* (TOAST): (1) Aterosclerose de Grandes Vasos (ATGV); (2) Cardioembolia; (3) Oclusão de Pequenos Vasos (OPV); (4) Outras Etiologias (OE) e (5) Indefinido⁴.

Os fatores de risco associados ao AVE, incluem: diabetes mellitus, hipertensão arterial, sedentarismo, tabagismo, doenças cardíacas, condições comportamentais (emocional e stress), hipercolesterolemia, obesidade e pré-disposições genéticas⁵. Além disso, o baixo nível de atividade física dos indivíduos é um grande fator de risco para o AVE, colaborando para o surgimento de outras doenças cardiovasculares e o aumento das incapacidades dos indivíduos, sinalizando que os fatores individuais influenciam no desenvolvimento dessa condição⁶.

Nesse contexto, alguns exames podem ajudar a diagnosticar o AVE, como os de neuroimagem: tomografia computadorizada, ecografia doppler transcraniana, angiografia cerebral e a imagem de difusão por ressonância magnética. Esses exames apresentam grande potencial para determinar o prognóstico funcional do AVE⁷. Porém, esses exames, muitas vezes, são insuficientes para o diagnóstico daquele indivíduo, principalmente em condições de AVE. Nesse contexto, a medicina de precisão auxilia na customização do diagnóstico e promete oferecer uma individualização do processo terapêutico, tornando a prática médica mais eficiente e diminuindo os custos⁸.

Dentro da medicina preditiva, os sistemas computadorizados de auxílio diagnóstico vêm sendo desenvolvidos com o objetivo de melhorar a acurácia dos exames, a consistência na interpretação de imagens médicas, a avaliação prognóstica e o suporte à decisão terapêutica, contribuindo, assim, para a medicina preditiva⁹. Essas ferramentas possuem potencial enorme, porém, há ainda limitações para seu uso na rotina clínica. Nesse contexto, as técnicas de Inteligência Artificial (IA), as quais podem ser definidas como modelos matemáticos e computacionais que imitam os processos de pensamento humano e a capacidade de aprendizagem e armazenamento de conhecimento estão sendo muito utilizadas, pois dão auxílio aos médicos na tomada de decisões clínicas, por poderem revelar informações clinicamente relevantes escondidas na enorme quantidade de dados, tornando mais fácil a análise caso a caso¹⁰.

Dentro da IA existe o campo do *machine learning* (aprendizado de máquina), o qual pode ser definido como um algoritmo de computador com a capacidade de aprender sobre um determinado conhecimento a partir de padrões de repetições¹¹. Sua aptidão de aprendizagem pode ocorrer de três maneiras: aprendizagem supervisionada, aprendizagem não supervisionada e aprendizagem por reforço¹³. A aprendizagem supervisionada é aplicada quando há uma base de dados que possuem rotulamento quanto a suas classes, já a aprendizagem não supervisionada ocorre quando não há rótulos disponíveis, pois nesse caso o que acontece é um agrupamento de estruturas de acordo com uma característica semelhante^{14,15}. Por fim, a aprendizagem por reforço ocorre quando há uma adaptação do modelo a cada nova situação, com inserção de novos dados^{13,14,15}.

As Redes Neurais Artificiais (RNAs) são um tipo de programa que formam algoritmos de aprendizado projetados para processar imagens de entrada e atribuir importância a vários aspectos para diferenciar uma imagem da outra^{10,11}. A arquitetura das RNAs é comparável à do padrão de conectividade dos neurônios no cérebro humano, seguindo um modelo hierárquico que cria uma estrutura semelhante a um funil para fornecer uma camada totalmente conectada onde todos os neurônios estão conectados e a saída é processada¹¹. São consideradas um tipo de aprendizagem supervisionada, pois estas utilizam um conjunto de dados rotulado, em que é possível aprender a função que mapeia os dados nos rótulos e, por esse motivo, são particularmente adequadas para dados de imagens médicas¹⁶. Essas RNAs são utilizadas no reconhecimento e classificação de padrões através de elementos de processamento altamente conectados capazes de fazer computações elementares¹⁷.

Essas aplicações na categoria supracitada de aprendizado de máquina também estão sendo utilizadas para auxiliar no processo de diagnóstico, prognóstico e tratamento de condições neurológicas, como, por exemplo, o AVE¹⁸. Entre as diferentes aplicações, essas RNAs usando como entrada (*input*) imagens de Ressonância Magnética (RM) e Tomografia Computadorizada (TC) podem auxiliar na previsão de déficits motores, cognitivos e sensoriais em pacientes com AVE^{18,19,20}. Em 2010, no evento ImageNet Large Scale Visual Recognition Challenge foi realizado um teste em que o desafio era classificar imagens de uma base contendo 1,2 milhões de imagens e 1000 categorias de objetos rotulados^{21,22}. Esse desafio trouxe à tona a utilização de arquiteturas de RNAs do tipo convolucionais profundas (DCNN – *Deep Convolutional Neural Networks*), que para alguns contextos têm obtido resultados superiores aos resultados obtidos por seres humanos^{21,22}.

Entretanto, a utilização das RNAs, apesar de demonstrar resultados superiores aos de humanos e outras técnicas convencionais como regressão linear, ainda é uma tecnologia que precisa de melhoramentos e mais resultados para avaliação da sua real acurácia e utilização

na prática clínica^{9,23}. A evolução ocorre à medida que novos problemas são tratados utilizando aprendizagem profunda e a popularização ocorre com o desenvolvimento de novas e mais simples bibliotecas de software para implementação de aprendizagem profunda^{21,22}. Dessa forma, o objetivo desta revisão será avaliar como as redes neurais artificiais estão sendo utilizadas para a predição de diagnóstico de AVE.

METODOLOGIA

O presente estudo é uma Revisão Sistemática, a qual baseia-se em um método de pesquisa pautado na síntese sistematizada de variados estudos e permite o estabelecimento de conclusões específicas acerca de um tema determinado. Diante disso, foram seguidas as oito etapas essenciais para a sua elaboração: (1) elaboração da pergunta de pesquisa; (2) busca na literatura; (3) seleção dos artigos; (4) extração dos dados; (5) avaliação da qualidade metodológica; (6) síntese dos dados (metanálise); (7) avaliação da qualidade das evidências e (8) redação e publicação dos resultados²⁴. Sendo assim, foi estabelecida a seguinte questão norteadora: "Como as redes neurais artificiais podem ser utilizadas para a predição de resultados neurocognitivos de longo prazo pós-AVE?".

A seleção desta revisão se deu por pares duplo cego, seguindo as recomendações do protocolo *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) para revisões de literatura²⁵. Os descritores utilizados para a busca foram: "stroke", "neural network" e "forecasting". A procura dos descritores se deu por meio da pesquisa nas bases DeCS (Descritores em Ciências da Saúde) e MeSH (*Medical Subject Headings*). O operador booleano utilizado foi o AND. Dessa forma, nas bases PubMed, BVS, SciELO e Cochrane a seguinte combinação foi utilizada: "stroke AND neural network", já na SpringerLink a combinação empregada foi: "stroke AND neural network AND forecasting". Na SpringerLink foram usados os três termos para refinar a busca na plataforma, devido à grande quantidade de artigos.

Buscando-se possibilitar uma seleção mais rigorosa dos estudos, os critérios de inclusão e filtros utilizados foram: (1) adequação ao tema; (2) artigo disponível (completo e gratuito); (3) trabalhos dos últimos 5 anos; (4) estudos em humanos; (5) estudos de triagem clínica, coortes ou ensaios controlados e (6) artigos nos idiomas inglês, português e espanhol. Os critérios de exclusão foram: (1) trabalhos duplicados; (2) indisponibilidade do texto (não gratuitos e/ou apenas resumidos); (3) artigos de revisão; (4) fuga ao tema proposto e (5) artigos que não preenchem todos os critérios de inclusão (artigos que não explicitaram que o método de machine learning utilizado era redes neurais e/ou artigos que não eram ensaios clínicos/estudos randomizados).

As bases de dados empregadas na pesquisa foram as cinco: (1) *PubMed (National Library of Medicine and National Institute of Health)*, BVS (Biblioteca Virtual em

Saúde), SciELO (*Scientific Electronic Library Online*), *Cochrane* e *SpringerLink*. Ao final do processo de seleção realizado a duplo cego, calculou-se o coeficiente de *Kappa* pelo aplicativo Bioestatística V.1.1.0, com o objetivo de avaliar o nível de concordância da seleção em pares que foi realizada, de forma que o valor de concordância foi calculado de acordo com um método categórico²⁶. O valor encontrado foi de: $K = 0,795$ (concordância substancial). Ademais, o protocolo desta revisão foi publicado no site do *International Prospective Register of Systematic Reviews* (PROSPERO) com o número de registro CRD42021290522.

Os artigos foram analisados criticamente por meio de três pessoas, dois observadores duplo cego e um revisor, a fim de avaliar sua qualidade individual, com base em dois estudos^{27,28}. Os 12 itens de avaliação da qualidade dos artigos estão detalhados abaixo, os quais são expressos por pontuações na Tabela 1, em que 0 = ausente; 1 = incompleto; e 2 = completo. O cálculo da porcentagem na Tabela 1 foi formado pela soma dos pontos alcançados em cada critério dividido pelo máximo esperado em cada item. Os resultados da avaliação para os 15 artigos selecionados, de acordo com os 12 critérios, estão representados abaixo.

Tabela 1. Análise da qualidade dos artigos selecionados para compor a análise qualitativa desta revisão sobre o uso de redes neurais para predição de resultados neurocognitivos de longo prazo em pacientes pós-AVE.

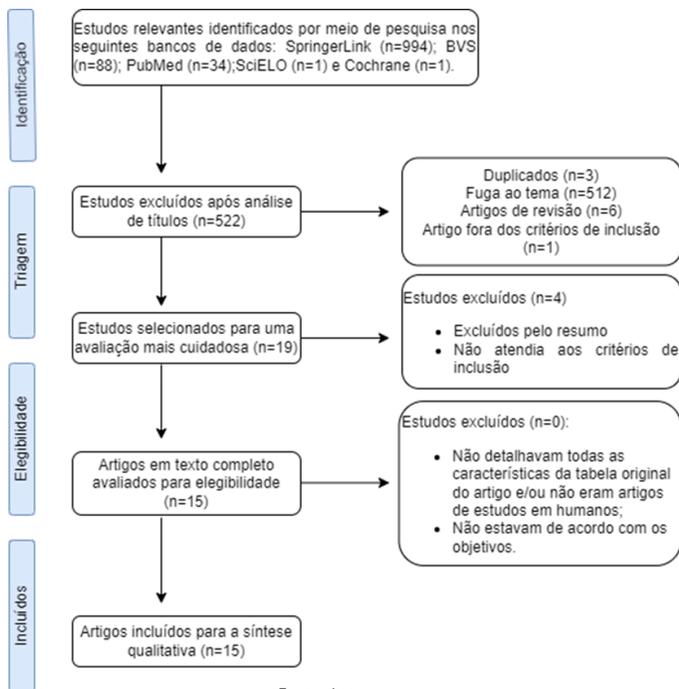
Estudos	Critérios de Avaliação												Total (%)
	1	2	3	4	5	6	7	8	9	10	11	12	
Abedi V et al., 2017 ²⁹	2	1	1	2	2	2	2	2	1	2	2	2	87,5%
Sharrock MF et al., 2020 ³⁰	2	2	2	1	1	1	2	2	2	2	2	1	83,3%
Kim YV et al., 2019 ³¹	2	2	2	2	2	1	2	2	1	2	2	1	87,5%
Sheth SA et al., 2019 ³²	1	2	2	2	2	1	2	2	1	2	2	2	87,5%
Hilbert A et al., 2019 ³³	2	2	2	2	2	1	2	2	2	2	2	2	95,83%
Subbanna NK et al., 2019 ³⁴	2	1	2	1	1	1	2	2	2	2	1	2	79,16%
Xiuli Q et al., 2021 ³⁵	2	1	2	2	1	1	2	2	1	2	2	2	83,3%
Yannan Y et al., 2020 ³⁶	2	2	2	2	2	2	2	2	1	2	2	2	95,83%
Tech D et al., 2018 ³⁷	1	2	2	2	1	1	2	2	1	2	2	2	83,3%
Govindarajan P et al., 2019 ³⁸	2	2	2	2	2	1	2	2	2	2	2	2	95,83%
Ona W et al., 2019 ³⁹	1	1	1	2	1	1	2	2	1	2	1	2	70,83%
van Os HJA et al., 2018 ⁴⁰	2	2	1	2	1	1	2	2	1	2	2	2	83,3%
Titano JJ et al., 2018 ⁴¹	2	1	2	1	1	1	2	2	2	2	2	2	83,3%
Guerrero R et al., 2018 ⁴²	2	1	2	2	1	1	2	2	1	2	2	1	79,6%
Mansour RF et al., 2021 ⁴³	2	1	1	1	1	2	2	2	2	2	2	2	83,3%

1 - Revisão e detalhamento de estudos na literatura para definição da pergunta da pesquisa; 2 - Critérios específicos de inclusão e exclusão; 3 - Objetivos específicos; 4 - Escopo apropriado das propriedades psicométricas; 5 - Justificativa e apresentação do tamanho da amostra; 6 - Acompanhamento dos pacientes; 7 - Procedimentos específicos de administração, execução e interpretação de resultados; 8 - Técnicas de medicação/avaliação apropriadas; 9 - Dados detalhados para cada hipótese; 10 - Estatísticas apropriadas; 11 - Estimativas de erros estatísticos; 12 - Conclusões válidas e recomendações clínicas. Score - 0 = ausente; 1 = incompleto; 2 = completo.

A partir da Tabela 1, é possível notar que a maioria dos artigos escolhidos para compor esta revisão são de boa qualidade, uma vez que 6 artigos tiveram avaliação de 83,3%, 3 com nota de 87,5%, 3 com nota de 95,83%, 2 com nota de, aproximadamente, 79%, um com score de 84% e um alcançou o score de, aproximadamente, 70%.

RESULTADOS

Após a seleção inicial foram obtidos, antes da aplicação dos filtros, os seguintes resultados: 2468 na SpringerLink; 3263 artigos na BVS; 1849 artigos no PubMed; 2 artigos na SciELO e 2 artigos na Cochrane, totalizando 7584 artigos. Após a aplicação dos filtros a soma de artigos nas bases foi de 541, dos quais 522 foram excluídos após análise de títulos. Dos 19 restantes, 4 foram excluídos após leitura dos resumos e os 15 restantes foram direcionados para uma leitura na íntegra por um 3º revisor. Desses, todos os 15 preencheram adequadamente todos os critérios de inclusão e foram selecionados para a análise qualitativa (Figura 1).



Fonte: Autor

Figura 1. Fluxograma da seleção crítica dos artigos realizada de acordo com as recomendações do protocolo PRISMA.

Dos 15 artigos selecionados para a síntese qualitativa, 3 deles são ensaios clínicos randomizados, 11 são triagens clínicas e 1 é coorte prospectivo. A Tabela 2 mostra os principais resultados dos estudos encontrados para a discussão. É separada por autores e ano de publicação, nº de pacientes estudados, tipo de estudo que foi realizado e principais evidências.

Tabela 2. Análise qualitativa para os dados dos 15 artigos selecionados contendo arguição sobre as principais evidências dos estudos analisados sobre o uso de redes neurais para predição de resultados neurocognitivos de longo prazo em pacientes pós-AVE.

Autor	N	Tipo de Estudo	Principais Evidências
Abodi V et al., 2017 ³⁹	260	Ensaio Clínico Randomizado	O modelo de RNA apresentou sensibilidade e especificidade médias para diagnóstico de ACI, com base na validação cruzada de 10 vezes, de 80% e 86,2%.
Sharrock MF et al., 2020 ³⁶	112	Triagem Clínica	Os resultados sugerem que modelos de rede neural profunda podem ser incorporados ao fluxo de trabalho em séries de ensaios clínicos de ICH, para segmentar de forma rápida e precisa, estimar o volume de hemorragia e reduzir falhas de segmentação.
Kim YV et al., 2019 ³¹	430	Triagem Clínica	O método apresentado é totalmente automático e tem alta correlação das medições do volume da lesão por difusão com segmentação manual e software comercial. O método tem potencial para ser usado na seleção de pacientes para terapia de reperfusão endovascular na janela de tempo tardia do AVE agudo.
Sheeth SA et al., 2019 ³³	297	Triagem Clínica	O algoritmo aprendeu a identificar a vasculatura intracerebral em CTA e detectou LVO com AUC 0,88. O método também foi capaz de determinar o início do infarto, a partir das imagens de origem do CTA com AUC 0,88 e 0,90.
Hilbert A et al., 2019 ³³	1301	Triagem Clínica	Os modelos tiveram um valor preditivo mais alto do que os modelos que usam biomarcadores de imagem radiológica comuns para previsão de resultados.
Subbanna NK et al., 2019 ³⁴	151	Ensaio Clínico Randomizado	A comparação das lesões de AVE segmentadas automaticamente com a segmentação manual, revelou um coeficiente de Dice médio de 0,582.
Xiuh Q et al., 2021 ³³	503	Coorte Prospectivo	O estudo encontrou fatores relacionados à ocorrência de PSD aos 3 meses em pacientes com excesso de peso. Enquanto os modelos RNA e DT foram construídos para uso médico.
Yaman Y et al., 2020 ³⁸	182	Triagem Clínica	O modelo parece ter predito lesões de infarto com sucesso a partir de imagens de base sem informações de reperfusão e alcançou desempenho comparável aos métodos clínicos existentes.
Teoh D et al., 2018 ³⁷	8000	Triagem Clínica	A rede neural combinou as fontes de dados temporais por meio de uma topologia de entrada dupla. Os termos de regularização personalizados tiveram um efeito positivo no processo de treinamento quando comparados com a função de perda de entropia cruzada padrão.
Govindarajan P et al., 2019 ³⁶	507	Triagem Clínica	As redes neurais artificiais treinadas com um algoritmo de gradiente descendente estocástico superaram os outros algoritmos com uma precisão de classificação superior de 95% e um desvio padrão menor de 14,69.
Ona W et al., 2019 ³⁹	2770	Triagem Clínica	A segmentação de lesões de ressonância magnética usando algoritmos de aprendizado profundo treinados com vários centros e dados diversos é viável e o volume e topografia podem ajudar na identificação do subtipo de AVE.
van Os HJA et al., 2018 ⁴⁰	1383	Triagem Clínica	Em pacientes com LVO, os algoritmos não superaram os modelos de regressão logística na previsão de reperfusão e independência funcional de 3 meses após o tratamento endovascular. Para todos os modelos no momento da admissão, o resultado radiológico foi mais difícil de prever do que o resultado clínico.
Titano JJ et al., 2018 ⁴¹	37.236	Ensaio Clínico Randomizado	O modelo se mostrou eficiente para fazer a triagem do fluxo de trabalho da radiologia e acelerar o tempo de diagnóstico de minutos para segundos.
Guerrero R et al., 2018 ⁴²	250	Triagem Clínica	A precisão de segmentação foi aprimorada em termos de pontuação de dados quando comparada a métodos de última geração bem estabelecidos.
Mansour RF et al., 2021 ⁴³	82	Triagem Clínica	O modelo AIBDA-ICH se mostrou efetivo para diagnóstico usando imagens de TC.

N - Número de pacientes estudados no artigo; RNA - Redes Neurais Artificiais; AVE - Acidente Vascular Cerebral; ACI - Isquemia Cerebral Aguda; CTA - angiografia por tomografia computadorizada; LVO - oclusão de grandes vasos; AUC - curva operativa do receptor; PSD - depressão pós-AVE; DT - árvore de decisão; ICH - hemorragia intracerebral; AIBDA-ICH - modelo de ICH e-diagnóstico baseado em analítica de big data; TC - Tomografia Computadorizada.

Quatro dos estudos selecionados^{30, 31, 33, 38} citaram índices de precisão diagnóstica para modelos de RNAs acima de 80%, sendo que um deles³⁸ citou um índice superior a 95%. Porém, outro estudo⁴⁰ cita que os algoritmos de redes neurais não superaram a capacidade preditiva dos modelos de regressão logística, contrariando outros artigos selecionados que mostram que modelos de predição baseados em redes neurais são efetivos para o diagnóstico de lesões cerebrais de origem vascular^{34, 36, 37, 41, 43}.

Além disso, vale mencionar que seis artigos acima descritos^{30, 33, 32, 37, 39, 42} utilizaram métodos de segmentação para avaliar variáveis como área da lesão, origem do infarto, topografia e extensão do edema, as quais são importantes para avaliar o nível do dano cerebral e prever o prognóstico do paciente com relação aos danos neurocognitivos, além de auxiliar na seleção de terapias de reperfusão endovascular nos pacientes como foi o objetivo de um dos artigos³¹. Além disso, um dos artigos utilizou a segmentação para classificar os subtipos de AVE e os mesmos autores mencionaram a importância de correlacionar esses dados com dados clínicos dos pacientes³⁹. Por fim, dois artigos^{41, 42} mencionaram que

esses métodos podem facilitar o diagnóstico diminuindo o tempo de minutos para segundos.

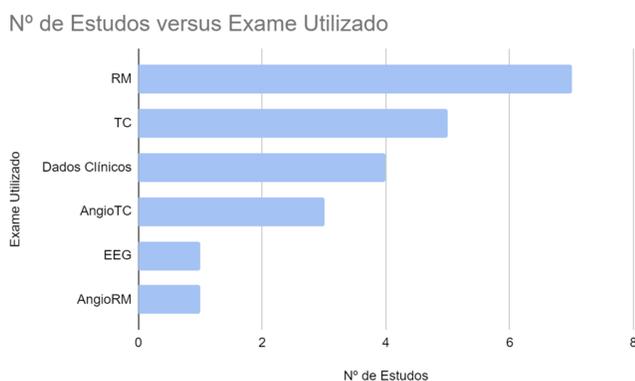


Figura 2. Análise quantitativa para os dados dos 15 artigos selecionados contendo informação sobre o nº de estudos selecionados versus tipo de exame complementar utilizado para o treinamento com o modelo de rede neural.

RM - Ressonância Magnética; TC - Tomografia Computadorizada; AngioTC - Angiotomografia Computadorizada; EEG - Eletroencefalograma; AngioRM - Angioressonância.

No gráfico acima estão descritos os tipos de exames utilizados para fazer predição de resultados pós-AVE nos estudos encontrados na literatura para modelos de redes neurais. Dessa forma, pode-se ver que a ressonância magnética foi o exame mais utilizado, sendo o tipo utilizado em 46,7% (n=7) dos estudos^{29,31,34,35,36,39,42}. Já a tomografia computadorizada está em segundo lugar, com 33,3% dos artigos (n=5)^{29,30,40,41,43}. Por fim, os dados clínicos estavam em 4 trabalhos^{29,35,37,38}, seguido de Angiotomografia com 3^{29,32,33} e EEG e Angioressonância com 1 estudo cada²⁹.

A tabela abaixo foi construída a fim de reunir dados sobre o autor, país de realização e país de publicação dos artigos selecionados, através da qual buscou-se extrair dados de possível predominância desses estudos que envolvem *machine learning* para avaliação do AVE em relação aos países.

Tabela 3. Georreferenciamento dos 15 artigos selecionados contendo dados sobre estudos envolvendo o uso de redes neurais para predição de resultados neurocognitivos de longo prazo em pacientes pós-AVE de acordo com os países.

Autor	País de Realização	País de Publicação
Abedi V et al., 2017 ⁽²⁹⁾	EUA	EUA
Sharrock MF et al., 2020 ⁽³⁰⁾	EUA	EUA
Kim YV et al., 2019 ⁽³¹⁾	Coreia do Sul	EUA
Sheth SA et al., 2019 ⁽³²⁾	EUA	EUA
Hilbert A et al., 2019 ⁽³³⁾	Holanda	EUA
Subbanna NK et al., 2019 ⁽³⁴⁾	Canadá	Suíça
Xiuli Q et al., 2021 ⁽³⁵⁾	China	Inglaterra
Yannan Y et al., 2020 ⁽³⁶⁾	EUA	EUA
Teoh D et al., 2018 ⁽³⁷⁾	Japão	Inglaterra
Govindarajan P et al., 2019 ⁽³⁸⁾	EUA	EUA
Ona W et al., 2019 ⁽³⁹⁾	EUA	EUA
van Os HJA et al., 2018 ⁽⁴⁰⁾	Holanda	Suíça
Titano JJ et al., 2018 ⁽⁴¹⁾	EUA	EUA
Guerrero R et al., 2018 ⁽⁴²⁾	Reino Unido	Holanda
Mansour RF et al., 2021 ⁽⁴³⁾	Colômbia	EUA

EUA - Estados Unidos da América.

Pode-se ver que grande parte (n=7, 47%) dos estudos foram realizados nos Estados Unidos da América e quantidade considerável (n=10, 67%) dos estudos foram publicados nesse mesmo país. Outros países apareceram mas com uma baixa frequência, tendo destaque apenas a Holanda como sendo o país de realização de 2 trabalhos e publicação de um.

DISCUSSÃO

O AVE é uma síndrome clínica complexa⁴⁴ com uma fisiopatologia bem definida, mas com um diagnóstico complicado devido a inespecificidade de sintomas^{45,46}. A lesão do AVE é inicialmente dividida em duas áreas: o núcleo do infarto, composto por tecido irreversivelmente danificado, e a penumbra, tecido em risco que ainda pode ser recuperado com restabelecimento do fluxo sanguíneo para a região. A localização e quantificação da região de núcleo e penumbra é de grande interesse clínico, pois pode ajudar a avaliar a quantidade de tecido que pode ser recuperada com diferentes tratamentos e tomar decisões mais bem informadas e auxiliar o paciente no processo de reabilitação⁴⁷. Para isso, as técnicas de IA podem auxiliar com os processos de classificação e segmentação.

A IA já era aclamada como uma solução promissora para auxiliar na detecção de doenças e auxiliar os médicos a fazerem diagnósticos precisos em menos tempo⁴⁸. Dentro da IA, existem as RNAs que são modelos computacionais baseados em redes neurais biológicas e são utilizadas para realizar o reconhecimento, classificação e segmentação de padrões através de elementos de processamento conectados e capazes de fazer computações elementares⁴⁵. As RNAs são muito utilizadas para processamentos de exames radiológicos na medicina, pois possuem uma grande capacidade de extrair dados de generalização, organização, tolerância e falhas de aprendizagem⁴⁸.

As DCNNs são caracterizadas por apresentarem centenas de camadas escondidas e podem auxiliar em processos de segmentação, que significa separar anatomicamente tecidos e estruturas entre normal versus patológico⁹. Porém, existem também as rotinas de classificação de imagens com uso de *machine learning* — usando, por exemplo, programas de RNAs. Classificar a imagem significa, em geral, defini-la dentro de uma categoria pré-estabelecida, como normal versus patológico e, para a classificação de diferentes modalidades de imagens médicas, utiliza-se uma variedade de atributos, para diversas doenças e ferramentas⁵⁰. O AVE é uma dessas condições que podem ser classificadas e segmentadas com uso de algoritmos.

De acordo com os resultados desta revisão, viu-se que a segmentação totalmente automatizada precisa de lesões isquêmicas é viável. Esses conjuntos de dados foram obtidos como parte da prática clínica de rotina envolvendo várias intensidades de campo, sequências, fornecedores e protocolos de aquisição que se estenderam por vários

anos, resultando em populações muito heterogêneas dentre os artigos selecionados^{30, 31, 33, 37, 39, 42}. Esse método de segmentação é preciso e pode ser usado para segmentação de vários tipos de lesões de AVE, com diversos tipos de imagem e isso pode ser corroborado por outro estudo que também realizou segmentação de imagens de AVE^{51, 52}, mostrando a importância desse método na identificação da área da lesão e sua topografia.

Outrossim, foi visto nos artigos selecionados que a especificidade, sensibilidade e a acurácia como um todo de um modelo de RNA é para classificação e segmentação de imagens é alto, permitindo extrair dados importantes, de forma que pode ser utilizado para apoiar a prática clínica^{29, 31, 33, 38}. Esses resultados podem ser confirmados por outro artigo⁵³ que mostra a capacidade desses algoritmos preditivos, uma vez que esses podem ter vários pontos operacionais, sua sensibilidade e especificidade podem ser ajustadas para atender aos requisitos clínicos. Esse mesmo trabalho⁵³ também mostra que os desempenhos de RNAs baseadas em aprendizado profundo é superior a métodos de regressão logística em termos de desempenho preditivo também como estabilidade preditiva, contrariando os autores de outro estudo da Tabela 1⁴⁰.

De acordo com o Figura 1 dos resultados dessa revisão, a ressonância magnética foi o exame mais utilizado, sendo o tipo presente em 46,7% dos estudos^{29,31,34,35,36,39,42}. Isso pode ser explicado porque imagens de ressonância magnética apresentam mais detalhes e são dispostas em vários planos e ponderações, o que facilita a visualização da imagem e inserção de parâmetros na RNA⁵⁴. Já a tomografia computadorizada está em segundo lugar, com 33,3% dos artigos^{29,30,40,41,43} e a Angiotomografia com 3^{29,32,33}, a TC apresenta um baixo custo e por isso, geralmente, é o método disponível, mas a AngioTC apesar da maior sensibilidade não é a mais utilizada⁵⁴. Por fim, os dados clínicos foram usados para modelagem do programa em 4 trabalhos^{29,35,37,38} seguidos de EEG e Angioressonância com 1 estudo cada²⁹.

As consequências do AVE são variadas, dependendo de vários fatores como a localização e a extensão da lesão e as condições de vida e saúde do paciente³¹. Dessa forma, se os fatores sociais forem ignorados, há um grande risco de se negligenciar e limitar o impacto dos danos pós-AVE na vida dos indivíduos. Por não conseguir se comunicar de forma satisfatória, os pacientes poderão se distanciar das atividades sociais, familiares e profissionais, resultando em uma participação social limitada⁵⁴. Nesse contexto, deve-se levar em consideração a perspectiva de clínica ampliada juntamente com a medicina de precisão, utilizando todos os métodos disponíveis para uma abordagem centrada no indivíduo^{9,36}.

CONCLUSÃO

Portanto, pode-se ver que as RNAs podem auxiliar na predição de diagnóstico nos pacientes através de métodos de segmentação e classificação, sendo que os primeiros apresentam uma alta especificidade e sensibilidade a fim de auxiliar no diagnóstico de AVE. Além disso, os métodos de neuroimagem como RM e TC podem ser vastamente utilizados para inserção de parâmetros nesses algoritmos pela sua ampla distribuição nos centros hospitalares, porém, métodos como AngioTC e AngioRM oferecem uma sensibilidade maior para análise de infartos. Dessa forma, as RNAs podem auxiliar na promoção de um cuidado individualizado, além de ajudar a encurtar o tempo de análise de exames em situações emergenciais, aumentar a confiança diagnóstica, tornar a análise de imagens objetiva e reprodutível e a reduzir o acúmulo de exames em alguns centros.

REFERÊNCIAS

1. Murphy SJX, Werring DJ. AVC: causas e características clínicas. *Remédio*. 2020;48 (9):561-6.
2. Ferreira AP, Ferreira YCLV, Boiani LE, Pompermaier C. Fatores de Risco para o Acidente Vascular Cerebral (AVC). In: *Anuário Pesquisa e Extensão UNOESC Xanxerê*; 2020; Santa Catarina. Santa Catarina. 2020;5:1-11.
3. Fernandes CGC, Ferreira DD, Furtado DBdR, Hartmann J, Winckler JL, Martins MIM et al. Independência funcional após acidente vascular cerebral (AVC) isquêmico em relação à fisiopatologia de acordo com TOAST. *Revista Brasileira de Neurologia*. 2021;57(1):13-26.
4. Costa M, Holsbach FB, Campos D, Valim ARM. Avaliação da Frequência de Acidente Vascular Cerebral Isquêmico com base no TOAST. *Interdisciplinaridade na promoção de saúde*. 2020.
5. Marques EA, Santos CTD, Amaral, MB, Paula SDS. Escalas aplicadas em pacientes com suspeita e diagnóstico de acidente vascular encefálico. *Revista Nursing*. 2019;22(251):2921-2925.
6. Simões TFP, Ferreira AJ, Martins JC, Faria CDCM. Physical activity levels of a primary health care users: comparisons between healthy subjects and subjects with stroke. *Acta Fisiátrica*;2017;24(2):56-61.
7. Branco JP, Costa JS, Sargento-Freitas J, Oliveira S, Mendes B, Laíns J. Neuroimaging and blood biomarkers in functional prognosis after stroke. *Acta Medica Portuguesa*. 2016;29(11):749-754.
8. Iriart JAB. Medicina de precisão/medicina personalizada: análise crítica dos movimentos de transformação da biomedicina no início do século XXI. *Cadernos de Saúde Pública* [online]. 2019;35(3):e00153118
9. Santos MK, Ferreira Júnior JR, Wada DT, Tenório APM, Barbosa MHN, Marques PMA. Artificial intelligence, machine learning, computer-aided diagnosis, and radiomics: advances in imaging towards to precision medicine. *Radiologia Brasileira* [online]. 2019;52(6):387-396
10. Braga AV, Lins AF, Soares LS, Fleury LG, Carvalho JC, Prado RS. *Braz. J. ofDevelop*. 2019;5(9):16407-16413.

11. Gu J, Wang Z, Kuen J, Ma L, Shahroudy A, Shuai B et al. Recent advances in convolutional neural networks. *Pattern Recognition*. 2018;77:354-377.
12. Jiang F, Jiang Y, Zhi H, Dong Y, Li H, Ma S et al. Artificial intelligence in healthcare: past, present and future. *Stroke Vasc Neurol*. 2017;2(4):230-243.
13. Ludermir TB. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. *Estudos Avançados [online]*. 2021;35(101):85-94.
14. Jiang F, Jiang Y, Zhi H, Dong Y, Li H, Ma S et al. Artificial intelligence in healthcare: past, present and future. *Stroke Vasc Neurol*. 2017;2(4):230-243.
15. Chauhan S, Vig L, De Filippo De Grazia M, Corbetta M, Ahmad S, Zorzi M. A Comparison of Shallow and Deep Learning Methods for Predicting Cognitive Performance of Stroke Patients From MRI Lesion Images. *Frontiers in Neuroinformatics*. 2019;13(53):1-12.
16. Bishop CM. *Pattern Recognition and Machine Learning*. 1. ed. Nova York, USA: Springer, 2006.
17. Patel UK, Anwar A, Saleem S, Malik P, Rasul B, Patel K et al. Artificial intelligence as an emerging technology in the current care of neurological disorders. *Journal of Neurology*. 2021;268(50):1623-1642.
18. Tayeb Z, Fedjaev J, Ghaboosi N, Richter C, Everding L, Qu X et al. Validating Deep Neural Networks for Online Decoding of Motor Imagery Movements from EEG Signals. *Sensors*. 2019;19(1):1-17.
19. Kamal H, Lopez V, Sheth SA. Machine Learning in Acute Ischemic Stroke Neuroimaging. *Frontiers in Neurology*. 2018;9(945):1-6.
20. Silva BK, Carro SA, Costa MG. Redes Neurais Aplicadas na Investigação de AVC por Tomografia Computadorizada. *Colloquium Exactarum*. 2019;11(1):53-64.
21. De Man R, Gang GJ, Li X, Wang G. Comparação de aprendizado profundo e desempenho do observador humano para detecção e caracterização de lesões simuladas. *J Med Imaging (Bellingham)*. 2019;6(2):025503.
22. Buetti-Dinh A, Galli V, Bellenberg S, Ilie O, Herold M, Christel S, et al. As redes neurais profundas superam a capacidade do especialista humano em caracterizar a composição do biofilme bacteriano de biolixiviação. *Relatórios de Biotecnologia*. 2019;22:1-5.
23. Jiang Y, Li C. Convolutional Neural Networks for Image-Based High-Throughput Plant Phenotyping: A Review. *Plant Phenomics*. 2020:4152816.
24. Galvão TF, Pereira MG. Revisões sistemáticas da literatura: passos para sua elaboração. *Epidemiologia e Serviços de Saúde*. 2014;23(1):183-184.
25. Galvão TF, Pansani TSA, Harrad D. Principais itens para relatar Revisões sistemáticas e Meta-análises: A recomendação PRISMA. *Epidemiologia e Serviços de Saúde*. 2015;24:335-342.
26. Landis JR, Koch GG. The Measurement of Observer Agreement for Categorical Data. *Biometrics*. 1977;33(1):159-174.
27. MacDermid JC, Walton DM, Avery S, Blanchard A, Etruw E, McAlpine C et al. Measurement Properties of the Neck Disability Index: A Systematic Review. *Journal of Orthopaedic & Sports Physical Therapy*. 2009;39(5):400-417.
28. Greenhalgh T. Assessing the methodological quality of published papers. *BMJ*. 1997;315:305-308.
29. Abedi V, Goyal N, Tsivgoulis G, Hosseinichimeh N, Hontecillas R, Bassaganya-Riera J, et al. Novel Screening Tool for Stroke Using Artificial Neural Network. *Stroke*. 2017;48(6):1678-81.
30. Sharrock MF, Mould WA, Ali H, Hildreth M, Awad IA, Hanley DF, et al. 3D Deep Neural Network Segmentation of Intracerebral Hemorrhage: Development and Validation for Clinical Trials. *Neuroinformatics*. 2021;19(3):403-415.
31. Kim YC, Lee JE, Yu I, Song HN, Baek IY, Seong JK, et al. Evaluation of Diffusion Lesion Volume Measurements in Acute Ischemic Stroke Using Encoder-Decoder Convolutional Network. *Stroke*. 2019;50(6):1444-51.
32. Sheth SA, Lopez-Rivera V, Barman A, Grotta JC, Yoo AJ, Lee S, et al. Machine Learning-Enabled Automated Determination of Acute Ischemic Core From Computed Tomography Angiography. *Stroke*. 2019;50(11):3093-100.
33. Hilbert A, Ramos LA, van Os HJA, Olabarriaga SD, Tolhuisen ML, Wermer MJH, et al. Data-efficient deep learning of radiological image data for outcome prediction after endovascular treatment of patients with acute ischemic stroke. *Computers in Biology and Medicine*. 2019;115:103516.
34. Subbanna NK, Rajashekar D, Cheng B, Thomalla G, Fiehler J, Arbel T, et al. Stroke Lesion Segmentation in FLAIR MRI Datasets Using Customized Markov Random Fields. *Front Neurol*. 2019;10:541.
35. Qiu X, Miao J, Lan Y, Sun W, Li G, Pan C, et al. Artificial neural network and decision tree models of post-stroke depression at 3 months after stroke in patients with BMI \geq 24. *Journal of Psychosomatic Research*. 2021;150:110632.
36. Yu Y, Xie Y, Thamm T, Gong E, Ouyang J, Huang C, et al. Use of Deep Learning to Predict Final Ischemic Stroke Lesions From Initial Magnetic Resonance Imaging. *JAMA Network Open*. 2020;3(3):e200772-e.
37. Teoh D. Towards stroke prediction using electronic health records. *BMC Medical Informatics and Decision Making*. 2018;18(1):127.
38. Govindarajan P, Soundarapandian RK, Gandomi AH, Patan R, Jayaraman P, Manikandan R. Classification of stroke disease using machine learning algorithms. *Neural Computing and Applications*. 2020;32(3):817-28.
39. Wu O, Winzeck S, Giese AK, Hancock BL, Etherton MR, Bouts M, et al. Big Data Approaches to Phenotyping Acute Ischemic Stroke Using Automated Lesion Segmentation of Multi-Center Magnetic Resonance Imaging Data. *Stroke*. 2019;50(7):1734-41.
40. van Os HJA, Ramos LA, Hilbert A, van Leeuwen M, van Walderveen MAA, Kruyt ND, et al. Predicting Outcome of Endovascular Treatment for Acute Ischemic Stroke: Potential Value of Machine Learning Algorithms. *Frontiers in Neurology*. 2018;9:784.
41. Titano JJ, Badgeley M, Schefflein J, Pain M, Su A, Cai M, et al. Automated deep-neural-network surveillance of cranial images for acute neurologic events. *Nature Medicine*. 2018;24(9):1337-41.
42. Guerrero R, Qin C, Oktay O, Bowles C, Chen L, Joules R, et al. White matter hyperintensity and stroke lesion segmentation and differentiation using convolutional neural networks. *NeuroImage: Clinical*. 2018;17:918-34.

43. Mansour RF, Escorcía-Gutierrez J, Gamarra M, Díaz VG, Gupta D, Kumar S. Artificial intelligence with big data analytics-based brain intracranial hemorrhage e-diagnosis using CT images. *Neural Computing and Applications*. 2021;1-15.
44. Damata SR, Formiga LMF, Araújo AKS, Oliveira EAR, Oliveira AKS, Formiga RCF. Perfil epidemiológico dos idosos acometidos por acidente vascular cerebral. *Revista Interdisciplinar*. 2016;9(1):107-117.
45. Silva BK, Carro SA, Costa MG. *Colloquium Exactarum*. 2019;11(1):53-64.
46. Santana MTM, Chun RYS. Linguagem e funcionalidade de adultos pós-Acidente Vascular Encefálico (AVE): avaliação baseada na Classificação Internacional de Funcionalidade, Incapacidade e Saúde (CIF). *CoDAS* 2017;29(1):e20150284.
47. Clèrigues A, Valverde S, Bernal J, Freixenet J, Oliver A, Lladó X. Segmentação do núcleo da lesão do AVC isquêmico agudo em imagens de perfusão de TC usando redes neurais totalmente convolucionais. *Computadores em Biologia e Medicina*. 2019;115:103487.
48. Heidari A, Navimopour JM. Um novo método de reconhecimento de SLA para descobrir os serviços em nuvem usando um algoritmo de otimização inspirado na natureza aprimorado. *PeerJ Comput. Sci.* 2021;7:e539.
49. Heidari A, Jafari Navimipour N, Unal M, Toumaj S. The COVID-19 epidemic analysis and diagnosis using deep learning: A systematic literature review and future directions. *Computers in Biology and Medicine*. 2022;141:105141.
50. Sharma N, Jain V, Mishra A. An Analysis Of Convolutional Neural Networks For Image Classification. *Procedia Computer Science*. 2018;132:377-84.
51. Liu L, Kurgan L, Wu FX, Wang J. Attention convolutional neural network for accurate segmentation and quantification of lesions in ischemic stroke disease. *Med Image Anal*. 2020;65:101791.
52. Scheulin KM, Jurgielewicz BJ, Spellacy SE, Waters ES, Baker EW, Kinder HA et al. Exploring the predictive value of lesion topology on motor function outcomes in a porcine ischemic stroke model. *Sci Rep*. 2021;11:3814.
53. Hung C, Chen W, Lai P, Lin C, Lee C. "Comparando rede neural profunda e outros algoritmos de aprendizado de máquina para previsão de acidente vascular cerebral em um banco de dados eletrônico de reivindicações médicas em larga escala populacional", In: 39th Annual Conferência Internacional do IEEE Engineering in Medicine and Biology Society (EMBC). 2017:3110-3113.
54. Karthik R, Menaka R, Johnson A, Anand S. *Computer Methods and Programs in Biomedicine*. 2020;197:105728.