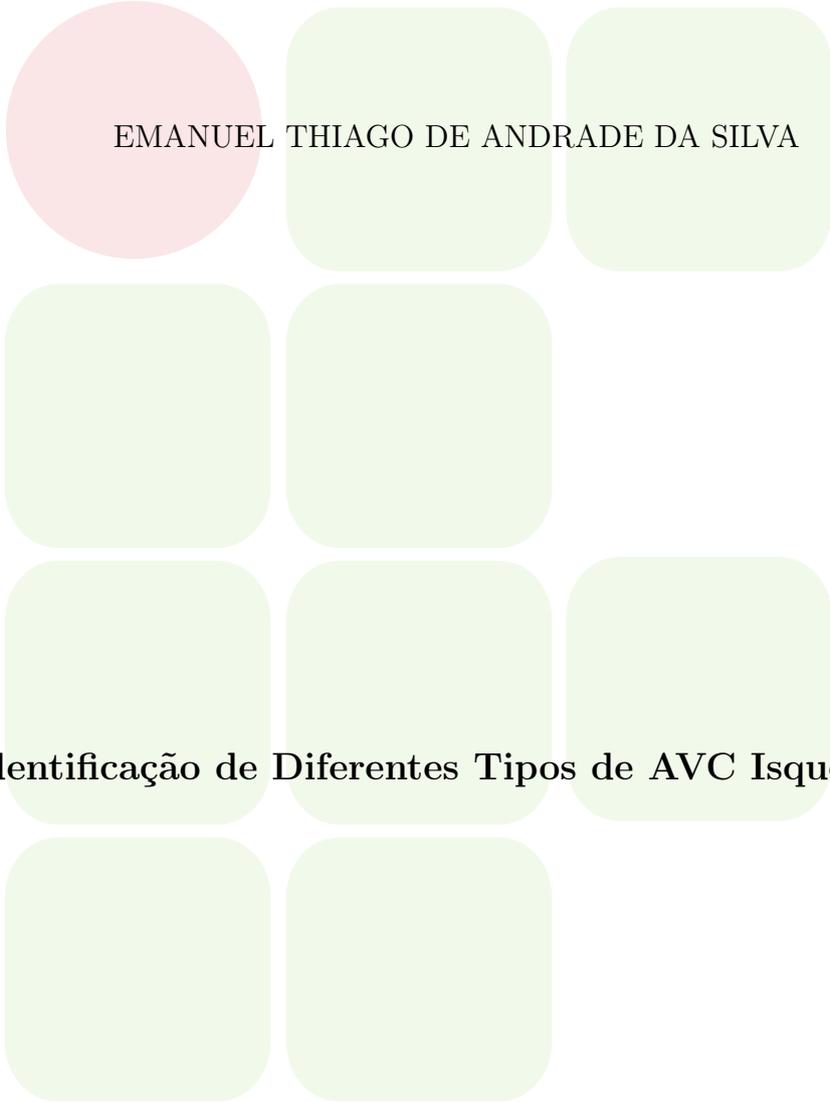


INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA
PARAÍBA

COORDENAÇÃO DO CURSO DE ENGENHARIA ELÉTRICA



EMANUEL THIAGO DE ANDRADE DA SILVA

Identificação de Diferentes Tipos de AVC Isquêmico

João Pessoa

2024

EMANUEL THIAGO DE ANDRADE DA SILVA

Identificação de Diferentes Tipos de AVC Isquêmico

Trabalho de Conclusão de Curso submetido à Coordenação do Curso de Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia da Paraíba, como parte dos requisitos para a obtenção do grau de Engenheiro Eletricista.

Orientador: Carlos Danilo Miranda Regis

João Pessoa
2024

Dados Internacionais de Catalogação na Publicação (CIP)
Biblioteca Nilo Peçanha, IFPB *campus* João Pessoa

S586a Silva, Emanuel Thiago de Andrade.

Auxílio na identificação de diferentes tipos de AVC isquêmico
/ Emanuel Thiago de Andrade da Silva. - 2024.

33 f. : il.

TCC (Graduação - Curso Superior de Bacharelado em Engenharia Elétrica) - Instituto Federal de Educação da Paraíba / Unidade Acadêmica de Processos Industriais, 2024.

Orientação : Prof. D.r Carlos Danilo Miranda Regis.

1.AVC isquêmico. 2. Redes neurais. 3. Processamento de imagem. 4. Imagem Dicom. 5. Tomografia computadorizada.

I.Título

CDU 616-073(043)

Elaboração: Lucrecia Camilo de Lima – Bibliotecária CRB 15/132

EMANUEL THIAGO DE ANDRADE DA SILVA

Identificação de Diferentes Tipos de AVC Isquêmico

Trabalho de Conclusão de Curso submetido à Coordenação do Curso de Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia da Paraíba, como parte dos requisitos para a obtenção do grau de Engenheiro Eletricista.

BANCA EXAMINADORA

Documento assinado digitalmente



Carlos Danilo Miranda Regis
Data: 01/03/2024 11:10:59-0300
Verifique em <https://validar.iti.gov.br>

Carlos Danilo Miranda Regis, Dr. – IFPB
Orientador

Documento assinado digitalmente



Suzete Elida Nobrega Correia
Data: 01/03/2024 15:03:56-0300
Verifique em <https://validar.iti.gov.br>

Suzete Élida Nóbrega Correia, Dra. – IFPB
Membro da Banca

Documento assinado digitalmente



PATRIC LACOUTH DA SILVA
Data: 01/03/2024 14:36:27-0300
Verifique em <https://validar.iti.gov.br>

Patric Lacouth da Silva, Dr. – IFPB
Membro da Banca

João Pessoa, 03 de fevereiro de 2024.

Agradecimentos

Primeiramente gostaria de agradecer a Deus por ter me dado as condições de chegar a esta etapa de minha vida.

Em seguida, gostaria de agradecer à minha família que também me deu condições para que eu pudesse focar nos estudos e que sempre me incentivou durante toda minha trajetória. Espero no futuro poder retribuir tudo o que fizeram por mim.

Não posso deixar de agradecer aos meus colegas de laboratório e amigos: Villaneve de Oliveira, Brenda Nogueira, Gabriel Diniz e João Neto, com os quais aprendi muito sobre como pesquisar e que sempre deram dicas sobre tópicos e tecnologias interessantes para serem estudadas.

Também agradeço ao meu orientador, o professor Danilo Regis que sempre se manteve do lado dos alunos nas situações em que precisamos e pela paciência nas disciplinas e na orientação dos trabalhos realizados.

Também sou grato aos amigos e colegas que fiz no IFPB, pelas incontáveis horas estudando para provas, jogando *online* ou conversando besteiras pelo pátio, fonte, lanchonetes ou *online*. Dentre esses amigos e colegas estão Villaneve, Rafael Chaves, Stephan, e Brenda Nogueira.

Para finalizar, gostaria de agradecer aos excelentes professores que tive durante toda a vida.

RESUMO

O acidente vascular cerebral (AVC) é uma das doenças que causa mais mortes e incapacidades físicas no mundo. O método mais comum para identificação do AVC, é o exame de tomografia computadorizada (CT). Este trabalho tem como objetivo identificar os diferentes tipos de AVC isquêmico (crônico, subagudo, e agudo), utilizando o redes neurais artificiais e métodos de processamento de imagens, tais como o método *Analysis of Brain Tissue Densities* (ABTD) adaptativo em imagens de computerized tomography (CT). Os melhores resultados obtidos foram no AVC crônico com a uma taxa de sensibilidade de 88,78%, precisão de 86,32%, e F1-score de 87,53%.

Palavras-chave: AVC, isquemia, redes neurais, processamento, imagem.

ABSTRACT

Stroke is one of the leading causes of death and physical disability worldwide. The most common method for stroke identification is computed tomography (CT) scanning. This work aims to identify different types of ischemic stroke (chronic, subacute, and acute) using neural networks and image processing methods such as the adaptive ABTD method in CT images. The best results obtained for chronic stroke were a sensitivity of 88.78%, accuracy of 86.32%, and F1-score of 87.53%.

Keywords: *Stroke. ischemic. Neural Networks. processing. Image.*

LISTA DE FIGURAS

Figura 1 – Estrutura de uma imagem no padrão DICOM.	13
Figura 2 – Diferença entre os métodos ABTD e ABTD adaptativo de (VASCON- CELOS et al., 2020).	16
Figura 3 – Topologia de uma rede neural do tipo MLP com duas camadas ocultas.	17
Figura 4 – Extração de padrões e redução de dimensionalidade por meio das ca- madas convolucionais e de <i>pooling</i> . Adaptada de (HAYKIN, 2008). . . .	18
Figura 5 – Fluxograma do processamento da imagem desenvolvido.	22

LISTA DE TABELAS

Tabela 1	– Resultados para as diferentes arquiteturas classificando AVC Crônico. .	26
Tabela 2	– Resultados para as diferentes arquiteturas classificando AVC Subagudo.	26
Tabela 3	– Resultados para as diferentes arquiteturas classificando AVC Agudo. .	26
Tabela 4	– Resultados do ABTD em uma MLP para AVC do tipo crônico	27
Tabela 5	– Resultados do ABTD em uma MLP para AVC do tipo subagudo . . .	27
Tabela 6	– Resultados do ABTD em uma MLP para AVC do tipo agudo	27

SUMÁRIO

1	INTRODUÇÃO	9
2	IMAGENS DICOM	12
2.1	Imagens DICOM	12
2.2	Método ABTD	14
2.3	ABTD adaptativo	14
2.4	Redes Neurais Artificiais RNA	16
2.5	Redes Neurais Convolucionais	18
2.6	Método de Otsu	20
2.6.0.1	Filtro de Sobel	21
3	METODOLOGIA	22
3.1	Banco de Dados Utilizado	23
3.2	Processamento da imagem	23
3.3	Configurações das redes neurais	23
3.4	Método para comparação dos resultados	24
4	RESULTADOS	26
4.1	Análise dos Resultados	26
5	CONCLUSÃO	29
	REFERÊNCIAS	30

1 Introdução

O acidente vascular cerebral (AVC) ou doença cerebrovascular é um dos principais causadores mortalidade, de incapacidade funcional, e uma das causas mais comuns de disfunção neurológica da população adulta de todo o mundo (OLSEN et al., 2002). É a terceira maior causa de morte natural da população mundial, atrás apenas do câncer e do infarto. Segundo a Organização Mundial de Saúde (OMS), 15 milhões de pessoas por ano são acometidos pelo AVC em todo o mundo, a cada quatro minutos uma pessoa morre.

Porém nos países em desenvolvimento e dentro das classes sociais mais baixas em todo o mundo essa tendência não se aplica, e a taxa geral dos afetados pelo AVC permanece alta (GO et al., 2014). O grupo das doenças cerebrovasculares ocupa o segundo lugar no índice da taxa de mortalidade no Brasil, sendo que o acidente vascular cerebral isquêmico (AVCI) é a sua manifestação mais prevalente (LOBO et al., 2021).

O AVC é a doença neurológica mais comum e mais potencialmente devastadora, por isso é responsável por um grande número de pesquisas e inovações na área de imagens médicas (NEURORADIOLOGY, 2012). O AVC é uma patologia que afeta os vasos sanguíneos que irrigam o território cerebral. Devido à falta de oxigenação, as células nervosas da área do cérebro afetada não são capazes de desempenhar suas funções básicas, podendo até chegar a morte. O AVC pode ser classificado em dois tipos: hemorrágico (AVCh), decorrente da ruptura de vasos sanguíneos que causa um extravasamento de sangue para o cérebro; e isquêmico (AVCi), decorrente da insuficiência de suprimento sanguíneo cerebral, podendo ser temporário (episódio isquêmico transitório, EIT) ou permanente.

O AVC isquêmico ocorre quando um vaso sanguíneo no pescoço ou no cérebro é bloqueado. O bloqueio pode ser causado pela formação de um coágulo dentro dos vasos sanguíneos do cérebro ou pescoço, chamado de trombose, ou pelo movimento do coágulo de uma parte do corpo como o coração para o cérebro, chamado de embolismo, ou até uma artéria muito apertada que encaminha o sangue para o cérebro, chamada de estenose. Isso pode deixar danos permanentes no cérebro ou até levar a morte. Tratamentos feitos nas primeiras 3 horas são mais eficientes para a cura e a prevenção de danos permanentes (FESKE, 2021) .

Segundo Rennert et al. (2019), cerca de 87% de todos os AVCs são do tipo isquêmico, e para o tratamento a diferenciação entre os dois tipos é de fundamental importância. Os AVCs isquêmicos podem ser classificados em três classes de evolução: agudo (0-24h), subagudo (24h-2 semanas) e crônico (mais de 2 semanas) (VU; GONZÁLEZ; SCHAEFER, 2006). A eficácia do tratamento está diretamente relacionada ao tempo decorrido do início do AVCI (WAJNGARTEN; SILVA, 2019).

O diagnóstico clínico do AVC isquêmico, através apenas de exames físicos, é difícil nas primeiras horas de acometimento da patologia, e sua rápida detecção é crucial para recuperação das funções. Seus sintomas são extremamente parecidos aos do AVC hemorrágico, porém o tratamento é completamente diferente (TOMURA et al., 1988) . Então é necessário o suporte de imagens cerebrais para a confirmação do diagnóstico e posterior intervenção médica.

Os dois tipos de exames mais utilizados para a obtenção de imagens cerebrais é a ressonância magnética (RM) e a tomografia computadorizada (TC) (RAJINI; BHAVANI,). Segundo Ojaghihaghi et al. (2017) a RM é mais sensível ao AVCi nos estágios iniciais (agudo/subagudo). Porém comparada à RM, a TC é mais acessível, mais barata e mais rápida (a que mais se encontra em hospitais da Paraíba), por isso nas últimas décadas a TC foi mais utilizada para exclusão da possibilidade de AVCh, pois esta patologia é representado na TC como uma intensidade de nível de cinza bem alta, contrastando bem com o tecido nervoso que o circunda, assim, sendo fácil sua detecção.

A TC sem utilização de contraste é comumente o primeiro exame radiológico a ser feito em uma pessoa com suspeita de AVC (RAJINI; BHAVANI,). Na tomografia computadorizada o AVCi aparece como uma região menos densa em relação ao tecido cerebral circundante. Nos estágios iniciais ocorre pouca distinção das cores nas imagens da TC, assim mesmo um especialista com extensa experiência pode não percebê-la e, dessa forma, não identificar o AVC isquêmico (HUDYMA; TERLIKOWSKI, 2008).

Existem diversos sistemas de detecção auxiliada por computador para imagens cerebrais na literatura, utilizando filtros parciais adaptativos de suavização (LEE et al., 2006), processamento de imagem baseado em *wavelets* (PRZELASKOWSKI et al., 2007), entre outros. Técnicas de *machine learning* também podem ser usadas para solucionar esse problema.

Alguns trabalhos buscam fazer a identificação do AVC isquêmico, em Aguiar (2017) é feito a classificação desses sinais de imagens CT usando técnicas de processamento de imagem e otimização por colônia de formiga, em Aguiar (2017) é feito essa classificação usando técnicas de processamento de imagens e descritor de haralick e redes neurais, em Vasconcelos et al. (2020) é apresentado uma técnica nova para a análise desse trabalho, *O Analysis of Brain Tissue Densities adaptative* (ABTDA), nesse é feito uma série de processamentos para melhorar na classificação de imagens CT de AVC isquêmico.

Nesse contexto o método ABTD adaptativo mostrado por vasconcelos2020artificial, mostra uma solução boa para esse problema, entretanto ele é testado apenas para casos de AVC na fase avançada, crônico ou agudo, quando não é nem necessário a confirmação por imagens para determinar o quadro de AVC.

Esse trabalho tem como objetivo de identificar os tipos de AVC isquêmico, agudo,

subagudo, e crônico, que dizem respeito ao avanço da patologia em ordem crescente utilizando o método ABTD e uma rede MLP e uma rede CNN. Essa comparação é importante devido a necessidade da rápida identificação do AVC nas fases iniciais da patologia.

2 Imagens DICOM

2.1 Imagens DICOM

Nos anos 70, com a introdução da tomografia computadorizada seguida por outros métodos digitais de diagnóstico por imagens, e com o aumento do uso de computadores para aplicações clínicas, a comissão ACR-NEMA (*American College of Radiology - National Electrical Manufacturers Association*) reconheceu a necessidade emergente de um novo método padrão para transferência de imagens e suas informações associadas entre os dispositivos e os usuários. Daí surge o padrão DICOM (*Digital Imaging and Communications in Medicine*), que é o conjunto de especificações detalhadas de como formatar e trocar imagens junto com suas informações associadas (ASSOCIATION; RADIOLOGY et al., 1998).

O objetivo inicial da criação do DICOM pela comissão ACR-NEMA, em 1983, para se desenvolver uma interface entre os equipamentos de imagens médicas (tomografia computadorizada, ressonância magnética, ultrassonografia, etc.) e qualquer dispositivo que necessite se comunicar, como os vários sistemas de informações de hospitais. E ainda permitir a criação de bases de dados com informações de diagnósticos que poderiam ser utilizados, vistos por uma ampla variedade de dispositivos de todo o mundo. E além das especificações para o *hardware*, o padrão também especifica um conjunto consistente de formato de dados, um mínimo conjunto de comandos de *software* que possibilitasse a visualização e a interpretação correta das imagens (ASSOCIATION; RADIOLOGY et al., 1998).

Esse padrão é responsável pela especificação das ligações de dispositivos de armazenamento e redes normatizadas. E também é responsável pela comunicação e arquivamento de imagens digitais, obtidas pela TC, ressonância magnética, ultrassonografia, entre outros métodos de diagnóstico por imagens. Há uma facilitação da operação em um ambiente de rede, utilizou os padrões internacionais que já existiam quando aplicável, e por si só estabelece uma documentação para padrões internacionais. Assim, o principal objetivo desse padrão é facilitar a transferência e interpretação das imagens médicas e suas informações adicionais (ASSOCIATION; RADIOLOGY et al., 1998).

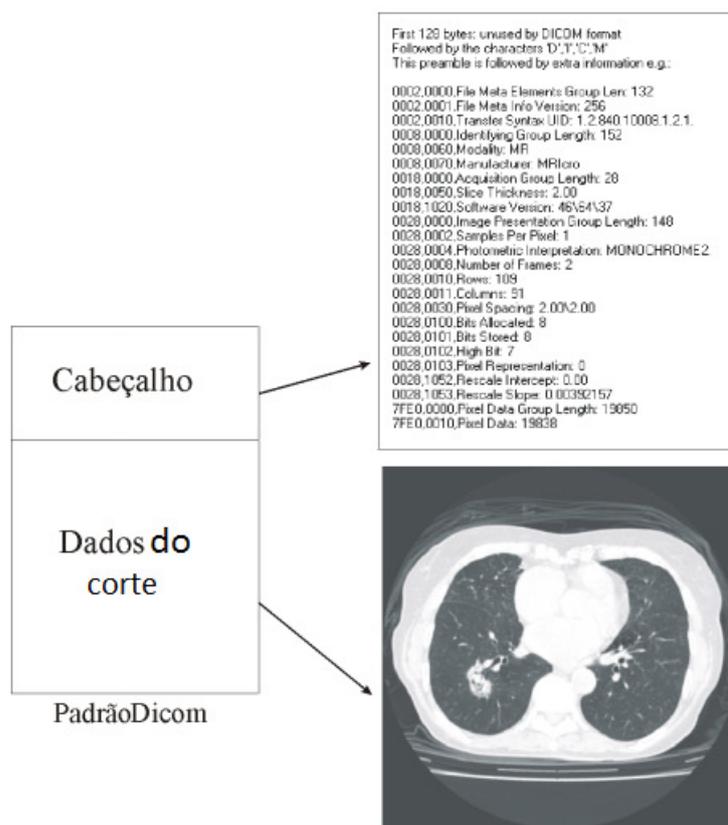
Apesar desse padrão ter sido desenvolvido inicialmente com ênfase nos diagnósticos de imagens médicas, praticado na radiologia, cardiologia e áreas relacionadas, o padrão é aplicável a uma ampla variedade de informações de imagens ou não trocadas na clínica médica ou em outros ambientes (ASSOCIATION; RADIOLOGY et al., 1998).

O padrão DICOM está em evolução, mas todas atualizações devem manter a compatibilidade eficaz com as edições anteriores. A adoção desse padrão pelas indústrias de

imagens médicas possibilita novas oportunidades de aumento de qualidade e eficiência nos cuidados aos pacientes. Permitindo que informações de um paciente percorra vários lugares diferentes através de um modem, barateando e aumentando a rapidez do cuidado à saúde (ASSOCIATION; RADIOLOGY et al., 1998).

Um arquivo DICOM é composto por um cabeçalho e definições de imagem. As informações como tipo de equipamento utilizado para obter a imagem, dimensões da imagem, entre outras, estão contidas no cabeçalho. Já a imagem propriamente dita está nas definições. Para melhorar o desempenho na transferência as imagens podem ser compactadas para reduzir o tamanho (MORAES, 2008). Na Figura 1 está ilustrada a estrutura da imagem no formato DICOM.

Figura 1 – Estrutura de uma imagem no padrão DICOM.



Fonte: (SILVA, 2004).

A TC armazena imagens no padrão DICOM que é uma imagem composta por 16 *bits*, 4 *bits* de informação textual, que pode conter informações do paciente tais quais gênero e idade, e 12 *bits* de exibição da imagem. O valor de atenuação de um *pixel* localizado em (i, j) é expresso em unidades de Hounsfield (UH), que é relacionado com o nível de cinza da imagem DICOM pela Equação (2.1). A configuração do redimensionamento de inclinação (m) e de interceptação (a) encontram-se nas informações textuais da imagem DICOM. O intervalo dinâmico da UH é amplo, de -1000 UH até 1000 UH.

$$UH(i, j) = m \times Y(i, j) + a \quad (2.1)$$

2.2 Método ABTD

O *Analysis of Brain Tissue Densities* (ABTD) ou Análise das Densidades do Tecido Cerebral (ADTC) é um método que realiza um cálculo percentual com base nos intervalos de densidade radiológica do cérebro humano para identificar tipos de AVC. O percentual é calculado da seguinte forma (FILHO et al., 2017):

$$P_i = \frac{f_{(vi)}}{\sum_{i=0}^{n-1} f_{(vi)}}, \quad (2.2)$$

na qual P_i é a porcentagem de cada região, vi são as classes possíveis, n é o número de tecidos diferentes considerados.

O $f_{(vi)}$ é a função com o número de pontos presentes na classe correspondente. Esta função pode ser determinada por:

$$f_{(vi)} = \sum_{i=0}^x \sum_{j=0}^y R(x, j), \quad (2.3)$$

em que,

$$R_{abtd}(x, y) = \begin{cases} 1 & \text{se } \lim_{inf} < T(x, y) < \lim_{sup} \\ 0 & \text{caso contrário} \end{cases} \quad (2.4)$$

e o \lim_{sup} e \lim_{inf} são os limites superior e inferior do intervalo de densidade, em HU, para cada classe vi , e $R_{abtd}(x, y)$ representa cada pixel analisado da imagem, enquanto $T(x, y)$ representa a a intensidade do pixel na posição x e y .

2.3 ABTD adaptativo

O método ABTD adaptativo é baseado no cálculo de uma probabilidade adaptada para cada pixel na imagem com base em sua vizinhança. O método difere do ABTD, que analisa toda a imagem para calcular uma probabilidade global.

O método proposto analisa a imagem pixel a pixel e verifica a vizinhança do pixel para decidir a qual região de densidade esse pixel pertence. Essa abordagem cria um novo mapa a partir do qual um percentual global de cada classe pode ser calculado, onde as equações estão apresentadas em Vasconcelos et al. (2020). Matematicamente, podemos expressar a probabilidade, P_i , para cada região de HU seguindo a seguinte equação:

$$P_i = \frac{F_{ci}}{\sum_{i=0}^{N-1} F_{ci}}, \quad (2.5)$$

em que, F_{ci} representa o número de pixels da classe ci que aparecem na imagem. Essa frequência pode ser calculada por:

$$F_{ci} = \sum_{x=0}^H \sum_{y=0}^W R(x, y), \quad (2.6)$$

em que H e W são a altura e a largura da imagem, respectivamente, e $R(x, y)$ é dado por:

$$R(x, y) = \begin{cases} 1, & c = \arg \max |C_{ri}| \\ 0, & \text{caso contrário.} \end{cases} \quad (2.7)$$

O C_{ri} é o vetor com o número de pixels ri pertencentes a cada região de HU, na vizinhança do ponto $P(x, y)$ e pode ser calculado da seguinte forma:

$$C_{ri} = \sum_{x=-a}^a \sum_{y=-b}^b S(a+x, b+y) \quad (2.8)$$

e

$$S(x, y) = \begin{cases} 1, & \text{se } \lim_{inf} < p(x, y) < \lim_{sup} \\ 0, & \text{caso contrário,} \end{cases} \quad (2.9)$$

na qual o \lim_{sup} e \lim_{inf} são os limites superior e inferior do intervalo de densidade, em HU.

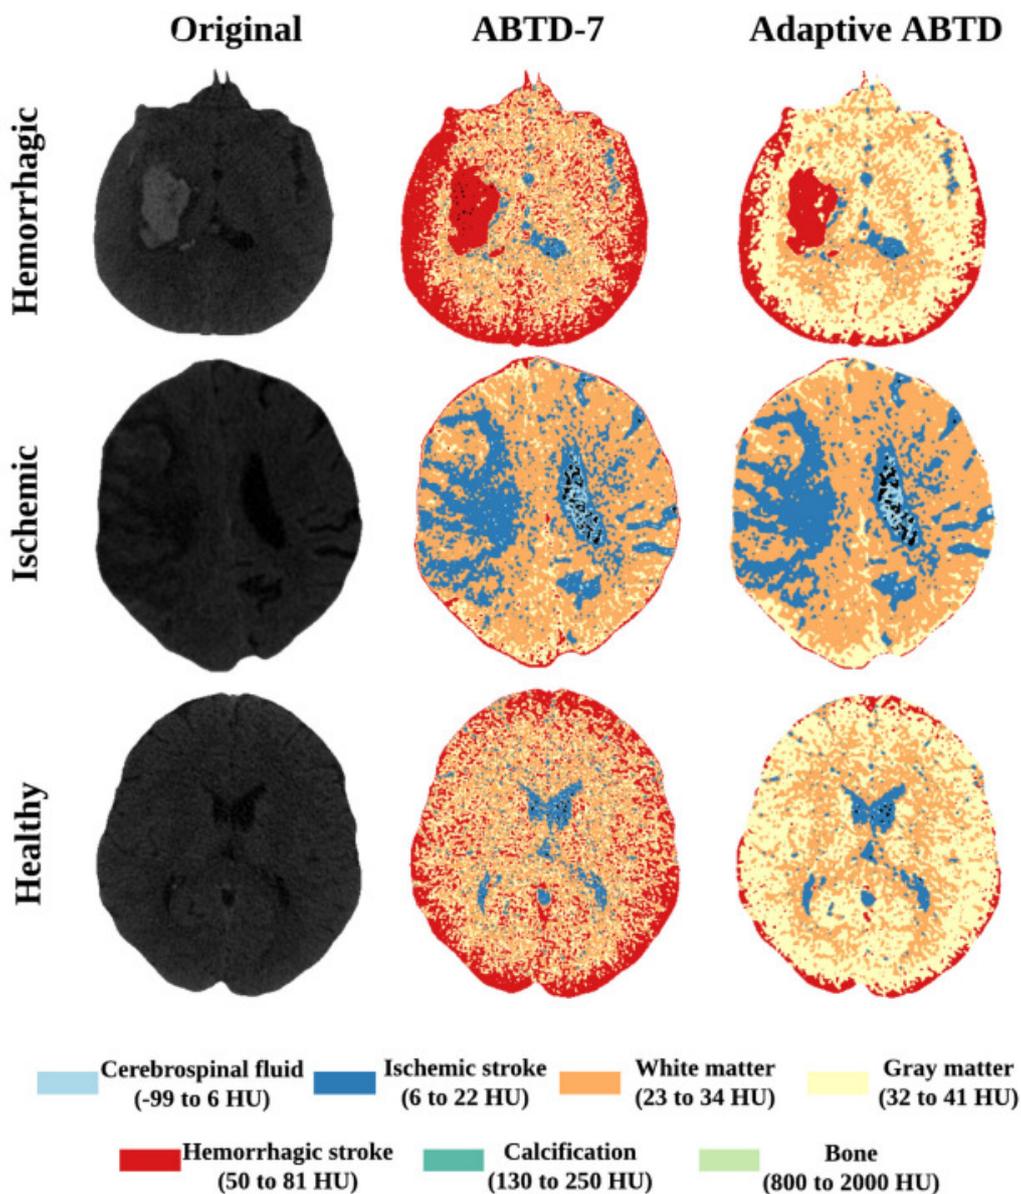
As regiões de Hounsfield (HU) usadas no ABTD Adaptativo (VASCONCELOS et al., 2020), são:

- Osso: 800 a 2000 HU;
- Calcificação: 130 a 250 HU;
- Acidente Vascular Cerebral Hemorrágico: 50 a 81 HU;
- Matéria Cinzenta: 32 a 41 HU;
- Matéria Branca: 23 a 34 HU;
- Acidente Vascular Cerebral Isquêmico: 6 a 22 HU;
- Líquido Cerebrospinal: -99 a 6 HU.

Essa faixa será usada nesse trabalho foi escolhida por Filho et al. (2017) porque possui mais detalhes das densidades do tecido cerebral, com uma classe separada para acidente vascular cerebral hemorrágico e isquêmico.

A imagem 2 mostra a comparação entre os métodos ABTD e ABTD adaptativo.

Figura 2 – Diferença entre os métodos ABTD e ABTD adaptativo de (VASCONCELOS et al., 2020).



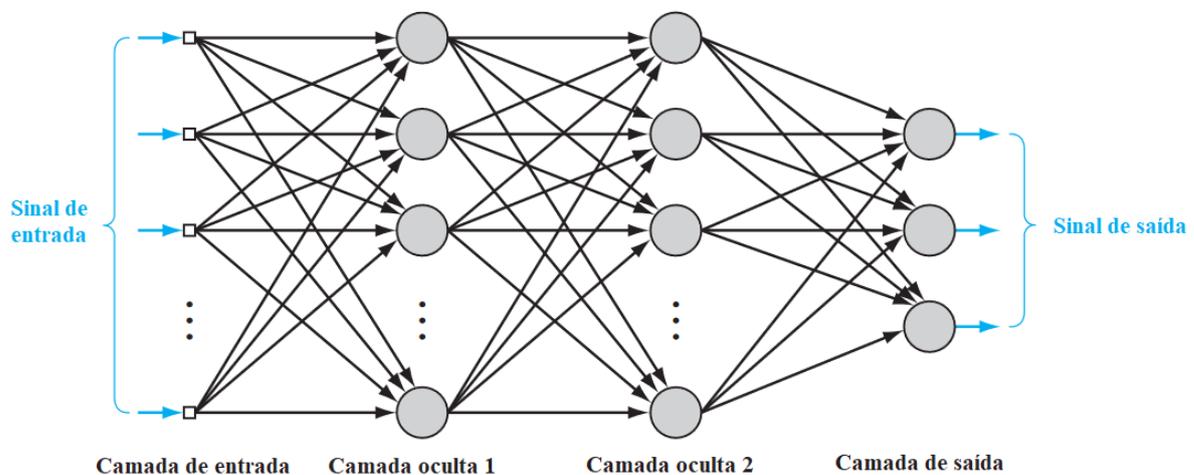
2.4 Redes Neurais Artificiais RNA

Uma RNA, segundo Haykin et al. (2009), é uma máquina que replica a forma que o cérebro faz uma tarefa ou uma função de interesse. Entre as RNAs existem aquelas que realizam computações por meio de um processo de aprendizagem e são compostas por um conjunto de unidades referidas como neurônios altamente conectados onde cada conexão possui um peso, sendo a modificação desses pesos uma forma de realizar o aprendizado

da tarefa designada, incluindo o reconhecimento de padrões e classificação (HAYKIN et al., 2009).

Em uma rede *Multilayer Perceptron* (MLP), a topologia é composta por ao menos três camadas de neurônios conectados entre elas, sendo uma camada de entrada, responsável por receber um vetor contendo as diferentes informações de entrada, uma camada de saída, a qual retorna um vetor de saída, e as demais consideradas camadas ocultas, responsáveis por realizar um mapeamento de forma não linear das entradas para as saídas correspondentes por meio da superposição de diversas funções de transferência (GARDNER; DORLING, 1998). Uma visualização dessa topologia é apresentada na Figura 3.

Figura 3 – Topologia de uma rede neural do tipo MLP com duas camadas ocultas.



Fonte: Adaptado de (HAYKIN et al., 2009).

Na Figura 3, cada círculo representa um neurônio, e cada seta representa o peso no neurônio referente à conexão entre eles. Estes pesos possuem inicialmente valores aleatórios, que são ajustados de acordo com a correlação de entrada e saída, durante o treinamento. O algoritmo de retropropagação ou *back-propagation*, é uma das abordagens mais utilizadas para ajuste dos pesos, a qual consiste na comparação da saída esperada com a saída obtida pela rede, o que retornou um sinal de erro. Esse sinal é propagado no sentido contrário (da camada de saída para a de entrada), camada por camada, onde os pesos vão sendo ajustados com o objetivo de minimizar o erro. Essas etapas são repetidas por um certo número de iterações ou até o erro ter um valor pequeno o suficiente (GARDNER; DORLING, 1998; HAYKIN et al., 2009).

No neurônio, também há uma função de transformação do sinal não linear em linear, chamada de função de ativação, responsável por limitar o sinal de saída a um intervalo, usualmente de 0 à 1, e com isso prover maior abstração das entradas para a rede. Atualmente é possível identificar na literatura diversas abordagens de funções de ativações, porém neste trabalho foram utilizadas as funções sigmóide (Equação 2.10) e ReLu (Equação 2.11) (HAYKIN et al., 2009). Além destas funções, no neurônio também

há um valor de erro sistemático chamado de viés, que somado ao produto das multiplicação dos pesos, neste contexto o viés é utilizado para auxiliar a função de ativação como peso de nivelamento.

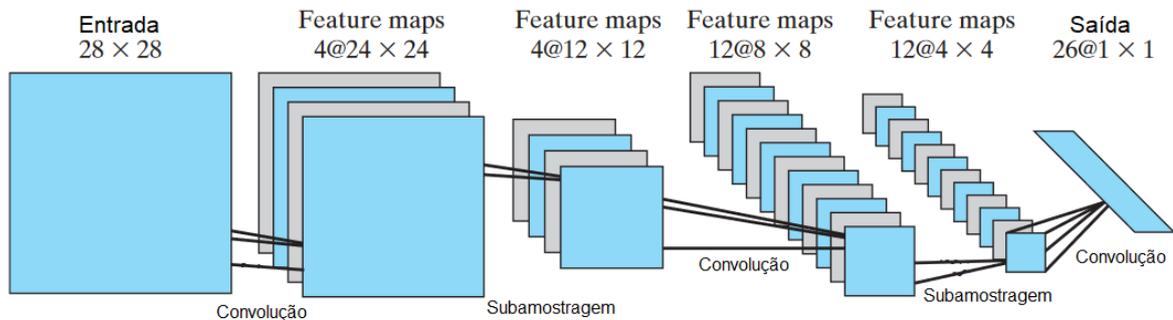
$$f(x) = \frac{1}{1 + \exp(-ax)}, a = 1 \quad (2.10)$$

$$f(x) = \max(0, x) \quad (2.11)$$

2.5 Redes Neurais Convolucionais

As *Convolutional Neural Networks* (CNN) são uma classe especial de redes de perceptrons multicamadas (MLP, *Multilayer Perceptron*) com foco no reconhecimento em duas dimensões de formas que possuem pouca variância à distorções como translação ou escalonamento (HAYKIN, 2008), com isso a identificação de alguma forma, como uma folha, por exemplo, em uma imagem passa a ser independente de sua posição na imagem (ALBAWI; MOHAMMED; AL-ZAWI, 2017).

Figura 4 – Extração de padrões e redução de dimensionalidade por meio das camadas convolucionais e de *pooling*. Adaptada de (HAYKIN, 2008).



Dentre as vantagens oferecidas por elas está a capacidade de reduzir a dimensionalidade de uma imagem de entrada ao mesmo tempo em que as características únicas para cada classe são capturadas. Em uma rede MLP convencional, imagens com dimensões maiores levam à um aumento na quantidade de pesos, o que ocasiona em um grande incremento no custo computacional e no tempo de treinamento. Ao considerar, por exemplo, uma imagem RGB com 32×32 de resolução, uma resolução baixa, para a qual os *pixels* atuarão como entrada para uma rede neural, caso a rede consista em apenas um neurônio, algo inviável para fazer o rotulamento de imagens, já serão necessárias $32 \times 32 \times 3$ conexões. Além disso, com um número maior de parâmetros há uma chance maior de ocorrer a redução na capacidade de generalização do modelo obtido pela rede (O'SHEA; NASH, 2015).

Alguns mecanismos para aprimorar a eficiência podem ser empregados para reduzir o número de pesos necessários sendo utilizados antes da etapa de classificação, entre esses mecanismos está fazer a extração de características seguida da redução da resolução delas.

A extração de cada atributo é feita por meio de um neurônio que recebe como entradas apenas uma região da camada anterior, de forma que apenas características locais são extraídas e, assim, há uma redução da importância da posição delas na imagem, sendo mais importante a posição relativa dela em relação a outros atributos (HAYKIN, 2008).

Um conjunto desses neurônios para extração de padrões, onde eles possuem o mesmo conjunto de pesos sinápticos é chamado de *feature map*, o que equivale a um filtro especializado à extração de uma característica em específico. Por esse compartilhamento nos pesos sinápticos, há uma redução no número de parâmetros. Além disso, em um *feature map*, por cada neurônio ser responsável pela extração da característica de apenas uma região local e por eles terem os mesmos pesos, isso equivale à operação de convolução dos elementos da camada anterior por um *kernel* treinável. Por causa disso, esses conjuntos de neurônios formam a camada convolucional. É importante destacar que o valor máximo dessa convolução é limitado pela função de ativação dos neurônios e que cada camada convolucional pode ser composta por diversos *features maps* (HAYKIN, 2008).

Por fim, cada camada convolucional é seguida de uma camada, chamada de camada de subamostragem ou de *pooling*, também treinável e com o compartilhamento de pesos entre cada *feature map*, para a redução da resolução de seu resultado, de forma que um novo *feature map* com dimensões menores é obtido a partir da obtenção do valor máximo ou valor médio de cada *feature map*, reduzindo a sensibilidade dessa saída do *feature map* à distorções (como deslocamento) (HAYKIN, 2008).

Vários conjuntos dessas camadas convolucionais e de *pooling* podem ser adicionadas de forma encadeada, fazendo com que a complexidade dos atributos extraídos aumente à medida que essa cadeia aumenta, ao mesmo tempo em que o número de características e de pesos treináveis diferentes não aumenta expressivamente devido à subamostragem e ao compartilhamento desses pesos, respectivamente. Esse processo de extração de características por meio de combinação dessas camadas pode ser observado na Figura 4.

Dentre os modelos base de CNN usualmente disponíveis estão a MobileNet-V2, ResNet-50, ResNet-101 e DenseNet-201 (MATHWORKS, 2022; CHOLLET et al., 2015), as quais são treinadas a partir da base de dados ImageNet, a qual contém mais de 14 milhões de imagens classificadas em 21841 categorias chamadas de *synset* (conjunto de sinônimos).

2.6 Método de Otsu

O método de Otsu utiliza o histograma da imagem para estabelecer um limiar ótimo de separação entre o objeto e o fundo da imagem, cada qual com suas características próprias (média, variância, desvio padrão, entre outras). Com o limiar de Otsu a imagem é binarizada em duas classes, uma classe formada pelos *pixels* que compõem o fundo da imagem e outra classe pelos *pixels* que compõem o objeto. Esse limiar é obtido automaticamente com base na análise discriminante. O limiar ótimo objetiva principalmente aumentar a variância entre as classes, e conseqüentemente, diminuir a variância dentro de um só classe (OTSU, 1975).

Considerando um histograma normalizado de uma imagem que possui intensidades representada por L níveis de cinza $[1, 2, \dots, L]$, em cada nível i existe uma quantidade de *pixels* n_i . O número total de *pixels* pode ser denotado por $N = n_1 + n_2 + \dots + n_L$ (OTSU, 1975). A probabilidade de ocorrência de um *pixel* no nível i é dada por:

$$p_i = n_i/N, \quad p_i \geq 0, \quad \sum_{i=1}^L p_i = 1. \quad (2.12)$$

Os *pixels* da imagem podem ser separados em duas classes C_0 e C_1 por um limiar no nível k . Essas duas classes representam o objeto e o fundo existentes na imagem, ou, o fundo da imagem e o objeto existentes na imagem (OTSU, 1975).

Considerando que C_0 corresponde aos *pixels* com níveis $[1, \dots, k]$, e C_1 aos *pixels* com níveis $[k + 1, \dots, L]$, a probabilidade de ocorrência e a média das classes podem ser determinadas, respectivamente, pelas equações 2.13 a 2.14,

$$\mu_0 = \sum_{i=1}^k iP(i | C_0) = \sum_{i=1}^k i \frac{P(C_0 | i)P(i)}{P(C_0)} = \sum_{i=1}^k \frac{ip_i}{w_0} = \frac{\mu(k)}{w(k)}, \quad (2.13)$$

$$\mu_1 = \sum_{i=k+1}^L iP(i | C_1) = \sum_{i=k+1}^L i \frac{P(C_1 | i)P(i)}{P(C_1)} = \sum_{i=k+1}^L \frac{ip_i}{w_1} = \frac{\mu_T - \mu(k)}{1 - w(k)}, \quad (2.14)$$

em que

$$\mu(k) = \sum_{i=1}^k ip_i, \quad \mu_T = \mu(L) = \sum_{i=1}^L ip_i, \quad (2.15)$$

e

$$w_0 = P(C_0) = \sum_{i=1}^k p_i = w(k), \quad w_1 = P(C_1) = \sum_{i=k+1}^L p_i = 1 - w(k). \quad (2.16)$$

As variâncias das classes C_0 e C_1 podem ser dadas pelas Equações 2.17 e 2.18, respectivamente.

$$\sigma_0^2 = \sum_{i=1}^k (i - \mu_0)^2 P(i | C_0) = \sum_{i=1}^k (i - \mu_0)^2 \frac{p_i}{w_0} \quad (2.17)$$

e

$$\sigma_1^2 = \sum_{i=k+1}^L (i - \mu_1)^2 P(i | C_1) = \sum_{i=k+1}^L (i - \mu_1)^2 \frac{p_i}{w_1}. \quad (2.18)$$

A variância intra-classe é definida pela Equação 2.19

$$\sigma_W^2 = w_0 \sigma_0^2 + w_1 \sigma_1^2. \quad (2.19)$$

Para determinar o limiar ótimo, k^* , a variância dentro de uma mesma classe é calculada para todos os possíveis valores de k . O limiar ótimo será o valor de k que minimiza a variância intra-classe (GONZALEZ; WOODS, 2010).

2.6.0.1 Filtro de Sobel

O filtro de Sobel é comumente usado para detecção de bordas em técnicas de processamento de imagens. É baseado na convolução matemática, onde uma matriz pequena, chamada de *kernel* ou filtro, é aplicado em uma imagem para extrair informações de bordas.

Segundo Alves, Júnior e Valente (2021), o filtro de Sobel é uma matriz 3x3 que consiste em duas matrizes menores, uma para detecção de bordas na direção do eixo x e outra na do y. Essas matrizes são feitas para destacar mudanças na intensidade do pixel nessas duas direções, que é tipicamente correspondente a direções verticais e horizontais na imagem.

Para aplicar o filtro de Sobel a uma imagem, a matriz é convolvida com a imagem. Para cada pixel, os valores da matriz do filtro são multiplicados com o valor do pixel correspondente da imagem, e então o resultado é somado para produzir uma única saída. Esse processo é repetido para cada pixel na imagem, produzindo uma nova imagem que destaca as bordas da imagem original.

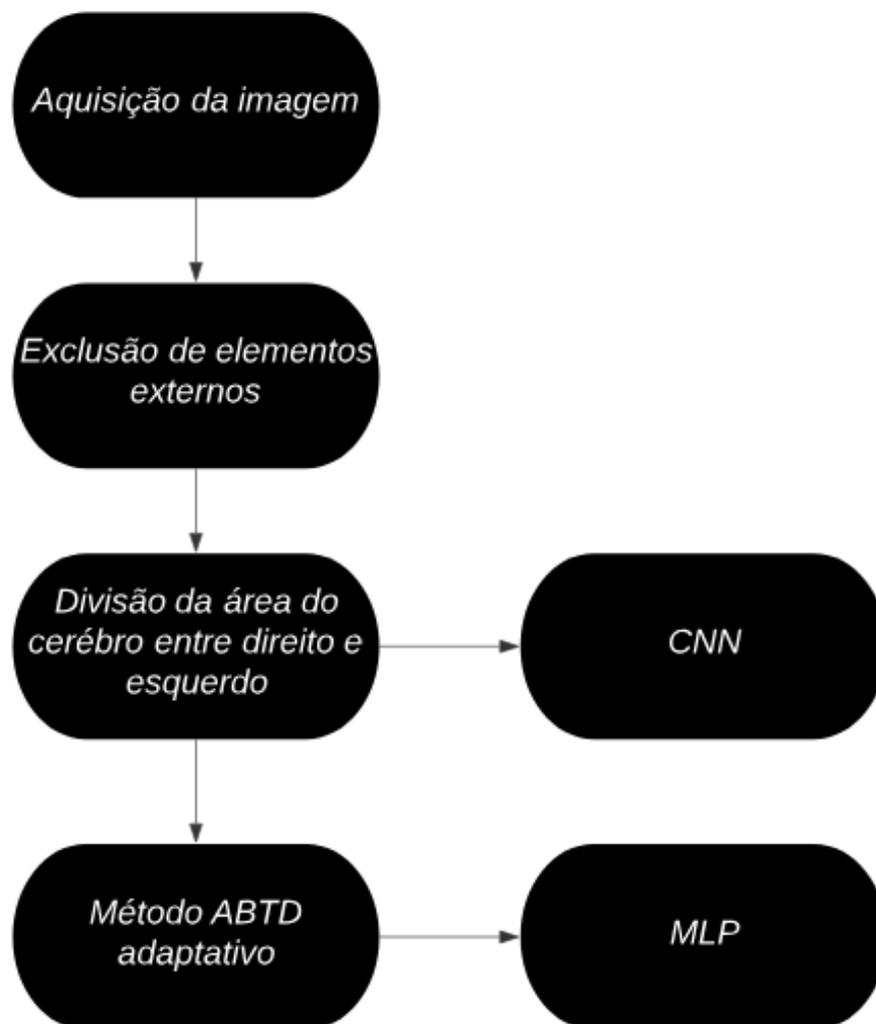
De acordo com SOUZA (2018), a fundamentação teórica do filtro de Sobel está no conceito do gradiente, que mede a taxa de mudança de uma função em um ponto particular.

Em um contexto de processamento de imagens, o gradiente é calculado pegando a derivada da função da intensidade de imagem em relação as direções x e y.

3 Metodologia

O desenvolvimento deste trabalho por ser visto como uma junção de várias etapas: a aquisição de um conjunto de imagens de uma base de dados, o processamento desses sinais que inclui a exclusão de elementos externos com o janelamento, divisão da área do cérebro entre direito e esquerdo, para um dos casos essa imagem será usada em uma rede neural CNN, e para outro será aplicado ao ABTD adaptivo e então testado com uma rede neural MLP, esse processo é mostrado na Figura 5.

Figura 5 – Fluxograma do processamento da imagem desenvolvido.



Fonte: Elaborada pelo autor.

Nas seções seguintes será descrito o conjunto de dados utilizado, explicado o processamento, apresentados os conceitos das redes neurais profundas utilizadas e sua confi-

guração.

3.1 Banco de Dados Utilizado

A base de dados utilizada neste projeto é composta por imagens de tomografia computadorizada da cabeça de 292 pacientes. Esse conjunto de dados foi disponibilizada pelo Núcleo de Estudos e Pesquisa em Imaginologia (NEPI) da Universidade Federal da Paraíba (UFPB). Todas as imagens seguem o padrão DICOM de imagens médicas e possuem dimensões de 512×512 originalmente. Cada exame de TC, de cada paciente, possui cerca de 20 imagens com o espaçamento de 8 mm entre os cortes axiais da cabeça. As imagens desses pacientes foram obtidas de forma aleatória em um clínica especializada em métodos de diagnóstico por imagem.

Os laudos de cada paciente foi realizado por um médico especialista na área de radiologia, ao qual indicará nas imagens de tomografia computadorizada de crânio os níveis de intensidade de tom de cinza característicos de uma área de AVC isquêmico crônico, agudo e subagudo, para que possa ser realizado a detecção do AVCi.

Na base de dados existem 47 pacientes com AVC, dentre esses 31 são subagudos, 9 agudos, e 7 crônicos.

3.2 Processamento da imagem

O processamento começa com a exclusão dos elementos externos que é feito com um janelamento de 0 a 150 em HU, após isso, é realizado uma limiarização global utilizando o método de Otsu e depois o filtro de Sobel para realizar a marcação da borda interna do crânio. Com essa borda foi preenchida com branco toda a parte interna e realizada a exclusão da parte externa.

Para a segmentação da área do AVC, foi realizada a divisão da área do AVC em direita e esquerda pelo fato do AVC normalmente só acontecer em um área. Com a divisão do cérebro duas etapas foram realizadas.

Para os testes realizados com o ABTD, é realizado o processamento do ABTD adaptivo nessa imagem resultante, para o caso da CNN, a imagem resultando é usada como entrada para a rede neural.

3.3 Configurações das redes neurais

Nesse trabalho foram usadas duas redes neurais, uma CNN, e uma MLP. A MLP teve suas suas configurações de hiper-parâmetros feitas usando o keras-turner, que busca determinar os melhores hiperparâmetros para maximizar uma certa característica, que nesse caso foi a sensibilidade.

Para a CNN foram utilizadas as seguintes arquiteturas de CNN: DensetNet201, MobileNetV2, ResNet50, ResNet101 (SANDLER et al., 2018; HE et al., 2016; HUANG et al., 2017). Todas as redes neurais foram feitas com a biblioteca keras e TensorFlow.

Na rede neural foi feito um balanceamento entre as imagens normais, então para o caso de AVC crônico foram usados 7 pacientes normais e 7 pacientes com AVC, para o agudo foram usados 9 pacientes normais e 9 pacientes com AVC, e para o AVC subagudo foram usados 31 pacientes normais e 31 pacientes com AVC.

Para a separação de datasets da rede neural artificial, foram usados 70% das imagens para treino, e 30% para validação.

3.4 Método para comparação dos resultados

O principal objetivo desse trabalho é comparar o desempenho diversos métodos para classificação do AVC isquêmico, que são classificados em três: crônico, subagudo e agudo.

Foram obtidos as métricas para esses tipos de AVC com uma MLP com o método ABTD, e também será usado uma CNN sem o método ABTD para fins de comparação. Além disso, os resultados foram executados 10 vezes por tipo de teste para garantir uma confiabilidade melhor na hora de comparar os resultados.

Para avaliar o desempenho das redes, foram utilizadas as métricas Precisão (Prec), Sensibilidade (Sen) e F1-Score.

A Precisão consiste na porcentagem de acerto dos sinais classificados como positivo, como observado na, Equação 3.1, na qual o TP diz respeito aos verdadeiros positivos, TN aos verdadeiros negativos, FP aos falsos positivos.

$$\text{Prec} = \frac{TP}{TP + FP} \quad (3.1)$$

A Sensibilidade por sua vez consiste em uma métrica que indica a tendência da rede em classificar sinais como positivos e pode ser entendida a partir da Equação 3.2, onde FN são os falsos negativos.

$$\text{Sen} = \frac{TP}{TP + FN} \quad (3.2)$$

O F1-Score pode ser entendido como a média harmônica entre precisão e sensibilidade e sua equação pode ser observada na Equação 3.3.

$$\text{F1} = 2 \cdot \frac{\text{Prec} \cdot \text{Sen}}{\text{Prec} + \text{Sen}} \quad (3.3)$$

Por fim, foi utilizado o *cross-entropy loss* para avaliar o aprendizado da rede neural artificial.

4 Resultados

4.1 Análise dos Resultados

Nesta seção são apresentados os resultados das métricas para identificação do AVC usando técnicas de processamento de imagens em uma CNN, conforme exibido na Tabela 1, 2 e 3, e da técnica do ABTD e uma MLP, testando nos dois tipos de AVC.

Tabela 1 – Resultados para as diferentes arquiteturas classificando AVC Crônico.

	DenseNet201	MobileNetV2	ResNet50	ResNet101
Prec(%)	82,23	70,14	70,53	77,26
Sen(%)	86,45	71,35	73,56	79,67
F1(%)	84,28	70,73	72,01	77,87
<i>loss</i>	0,403	0,598	0,714	0,396

Tabela 2 – Resultados para as diferentes arquiteturas classificando AVC Subagudo.

	DenseNet201	MobileNetV2	ResNet50	ResNet101
Prec(%)	76,25	68,14	66,53	72,84
Sen(%)	79,27	68,06	71,51	74,23
F1(%)	78,52	68,24	70,15	75,14
<i>loss</i>	0,498	0,687	0,925	0,456

Tabela 3 – Resultados para as diferentes arquiteturas classificando AVC Agudo.

	DenseNet201	MobileNetV2	ResNet50	ResNet101
Prec(%)	75,78	67,35	68,34	71,56
Sen(%)	76,39	68,65	73,55	73,15
F1(%)	76,08	67,99	70,84	72,34
<i>loss</i>	0,512	0,602	0,759	0,452

Deve-se destacar que o F1-Score é a principal métrica a ser observada, por ser a média harmônica entre sensibilidade e precisão, entretanto, em se tratando de um sistema de identificação de patologias, a sensibilidade deve receber atenção especial, sendo preferível uma alta sensibilidade, além disso também é mostrado o valor final do *loss*.

Para os casos de AVC crônico, na DenseNet201 observam-se os maiores valores em todas as métricas com exceção do *loss*. Nela foram obtidos os seguintes valores das métricas: F1-Score, 84,28%; precisão de 82,23%; sensibilidade 86,45%; e *loss* de 0,403.

Já para os casos de AVC subagudo, observa-se uma diminuição nas métricas, isso é um resultado esperado e acontece devido ao AVC subagudo ter uma cor parecida com a massa do cérebro, enquanto no agudo e crônico a diferença é mais clara visualmente. Nesses a DenseNet201 continua apresentando os melhores valores com exceção do *loss*, nela foram obtidos os seguintes valores das métricas: F1-Score, 78,52%; precisão de 76,25%; sensibilidade 79,27%; e *loss* de 0,498.

Nos casos de AVC agudo, observa-se um comportamento semelhante ao AVC subagudo, uma diminuição geral nas métricas pelos mesmos motivos, observando-se os seguintes resultados: F1-Score, 76,08%; precisão de 75,78%; sensibilidade 76,39%; e *loss* de 0,512.

Para o *loss* a melhor rede neural observada foi a resNet101. As demais redes, MobileNetV2 e ResNet50, apresentaram métricas inferiores a DenseNet201 no geral, portanto não sendo aplicáveis para esse trabalho.

Para o segundo teste, que envolve a utilização da ABTD com a MLP, os resultados estão mostrados na Tabela 4, 5 e 6. As mesmas métricas usadas para o método da CNN foram usadas nesta etapa.

Tabela 4 – Resultados do ABTD em uma MLP para AVC do tipo crônico

Métricas	Resultados
Precisão(%)	86,32
Sensibilidade(%)	88,78
F1-Score(%)	87,53
<i>loss</i>	0,502

Tabela 5 – Resultados do ABTD em uma MLP para AVC do tipo subagudo

Métricas	Resultados
Precisão(%)	72,47
Sensibilidade(%)	74,35
F1-Score(%)	73,29
<i>loss</i>	0,781

Tabela 6 – Resultados do ABTD em uma MLP para AVC do tipo agudo

Métricas	Resultados
Precisão(%)	70,15
Sensibilidade(%)	68,26
F1-Score(%)	69,19
<i>loss</i>	0,732

Comparando os resultados das Tabelas 4 e 5 é notável a diferença quando se usa AVC do tipos crônico, sub-agudo, e agudo nesse caso o método ABTD mostra dificuldades

para classificar o AVC, quando comparado com as Tabelas 1 e 2 e 3 percebe-se que o ABTD mostra resultados superiores a CNN quando é usado somente AVC do tipo crônico, e resultados inferiores a CNN quando usados AVC do tipo sub-agudo e agudo.

5 Conclusão

Com base nos resultados obtidos, é possível fazer algumas conclusões em relação à utilização de diferentes técnicas para identificação de AVC (Acidente Vascular Cerebral). Primeiramente, ao analisar os resultados das redes neurais convolucionais (CNNs), observa-se que a DenseNet201 demonstrou desempenho superior em comparação com as outras arquiteturas (MobileNetV2, ResNet50 e ResNet101), tanto para AVC agudo e crônico quanto para AVC subagudo, com exceção do valor de perda (*loss*). Isso sugere que a DenseNet201 é mais eficaz na diferenciação entre os tipos de AVC, principalmente devido à sua capacidade de capturar características mais complexas e detalhadas nas imagens.

Entretanto, é importante notar que a identificação do AVC subagudo apresentou desafios adicionais devido à sua semelhança visual com a massa cerebral. Isso resultou em uma redução geral nas métricas de desempenho para todos os modelos testados, o que indica a complexidade da tarefa de classificação nesses casos.

Por outro lado, ao empregar o método ABTD (Aprendizado Baseado em Transferência de Domínio) em uma MLP (Perceptron Multicamadas), os resultados mostraram um desempenho competitivo para AVC agudo e crônico, superando as CNNs em termos de precisão, sensibilidade e F1-Score. No entanto, quando aplicado ao AVC subagudo, o ABTD na MLP apresentou um desempenho inferior em comparação com as CNNs.

Essa discrepância nos resultados sugere que a escolha da técnica de classificação pode depender das características específicas do conjunto de dados e da natureza das imagens envolvidas. Enquanto as CNNs parecem mais robustas e eficientes na diferenciação entre os diferentes tipos de AVC, o ABTD na MLP pode ser uma opção viável em determinados contextos, especialmente quando se prioriza a precisão e sensibilidade em casos específicos, como AVC agudo e crônico.

Portanto, conclui-se que o ABTD não é tão confiável para todo tipo de imagem e também como método de exame geral, quando testado contra CNN usadas pela industrial e com uma técnica de processamento de imagem similar mostrou resultados inferiores para esses casos.

REFERÊNCIAS

- AGUIAR, C. *Avaliação de acidente vascular cerebral em tomografia computadorizada utilizando algoritmo de otimização de formigas*. Dissertação (Mestrado), 2017.
- ALBAWI, S.; MOHAMMED, T. A.; AL-ZAWI, S. Understanding of a convolutional neural network. In: IEEE. *2017 International Conference on Engineering and Technology (ICET)*. [S.l.], 2017. p. 1–6.
- ALVES, I. C.; JÚNIOR, C. G. F.; VALENTE, I. R. Processamento digital de imagens usando redes de petri coloridas-estudo de caso com filtro de sobel. In: *Simpósio Brasileiro de Automação Inteligente-SBAI*. [S.l.: s.n.], 2021. v. 1, n. 1.
- ASSOCIATION, N. E. M.; RADIOLOGY, A. C. of et al. *Digital imaging and communications in medicine (DICOM)*. [S.l.]: National Electrical Manufacturers Association, 1998.
- CHOLLET, F. et al. *Keras*. 2015. <<https://keras.io>>.
- FESKE, S. K. Ischemic stroke. *The American journal of medicine*, Elsevier, v. 134, n. 12, p. 1457–1464, 2021.
- FILHO, P. P. R. et al. Novel and powerful 3d adaptive crisp active contour method applied in the segmentation of ct lung images. *Medical image analysis*, Elsevier, v. 35, p. 503–516, 2017.
- GARDNER, M. W.; DORLING, S. Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric environment*, Elsevier, v. 32, n. 14-15, p. 2627–2636, 1998.
- GO, A. S. et al. Heart disease and stroke statistics—2014 update: a report from the american heart association. In: . [S.l.: s.n.], 2014. v. 129, n. 3, p. 138–163.
- GONZALEZ, R. C.; WOODS, R. E. *Processamento de Imagens Digitais*. Tradução de Cristina Yamagami e Leonardo Piamonte. 3. ed. São Paulo: Pearson Prentice Hall, 2010.
- HAYKIN, S. O. *Neural Networks and Learning Machines*. 3rd. ed. Ontario: Pentrice Hall, 2008.
- HAYKIN, S. S. et al. *Neural networks and learning machines/Simon Haykin*. [S.l.]: New York: Prentice Hall, 2009.
- HE, K. et al. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 770–778.
- HUANG, G. et al. Densely connected convolutional networks. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2017. p. 4700–4708.
- HUDYMA, E.; TERLIKOWSKI, G. Computer-aided detecting of early strokes and its evaluation on the base of ct images. In: IEEE. *Computer Science and Information Technology, 2008. IMCSIT 2008. International Multiconference on*. [S.l.], 2008. p. 251–254.

- LEE, Y. et al. Detectability improvement of early sign of acute stroke on brain ct images using an adaptive partial smoothing filter. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *Medical Imaging*. [S.l.], 2006. p. 61446Q–61446Q.
- LOBO, P. G. G. A. et al. Epidemiologia do acidente vascular cerebral isquêmico no brasil no ano de 2019, uma análise sob a perspectiva da faixa etária. *Brazilian Journal of Health Review*, v. 4, n. 1, p. 3498–3505, 2021.
- MATHWORKS, T. *Pretrained Deep Neural Networks*. 2022. Available in: <https://www.mathworks.com/help/deeplearning/ug/pretrained-convolutional-neural-networks.html>. Acesso em: Julho de 2022.
- MORAES, S. A. *Uma sugestão para o desenvolvimento de software baseado no protocolo DICOM Caso Invesalius*. Lavras, Minas Gerais, Brasil, 2008.
- NEURORADIOLOGY, A. S. of. *Stroke*. [S.l.], 2012. Disponível em: <<http://www.asnr.org/patientinfo/conditions/stroke.shtml#sthash.uGVPx4QV.dpbs>>. Acesso em: Fev. 2015.
- OJAGHIHAGHIGHI, S. et al. Comparison of neurological clinical manifestation in patients with hemorrhagic and ischemic stroke. *World journal of emergency medicine*, The Second Affiliated Hospital of Zhejiang University School of Medicine, v. 8, n. 1, p. 34, 2017.
- OLSEN, T. et al. European stroke initiative recommendations for stroke management-update 2003. In: . [S.l.: s.n.], 2002. v. 16, n. 4, p. 311–337.
- O’SHEA, K.; NASH, R. An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*, 2015.
- OTSU, N. A threshold selection method from gray-level histograms. In: . [S.l.: s.n.], 1975. v. 11, n. 285-296, p. 23–27.
- PRZELASKOWSKI, A. et al. Improved early stroke detection: wavelet-based perception enhancement of computerized tomography exams. In: . [S.l.]: Elsevier, 2007. v. 37, n. 4, p. 524–533.
- RAJINI, N. H.; BHAVANI, R. Computer aided detection of ischemic stroke using segmentation and texture features. In: . [S.l.: s.n.].
- RENNERT, R. C. et al. Epidemiology, natural history, and clinical presentation of large vessel ischemic stroke. *Neurosurgery*, Wolters Kluwer Health, v. 85, n. Suppl 1, p. S4, 2019.
- SANDLER, M. et al. Mobilenetv2: Inverted residuals and linear bottlenecks. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2018. p. 4510–4520.
- SILVA, A. C. Algoritmos para diagnostico assistido de nodulos pulmonares solitarios em imagens de tomografia computadorizada. In: . [S.l.: s.n.], 2004.
- SOUZA, R. S. d. *Método de detectar e validar bordas de corpos hídricos utilizando imagens de alta resolução e pontos de controle por gps*. Dissertação (B.S. thesis), 2018.

TOMURA, N. et al. Early ct finding in cerebral infarction: obscuration of the lentiform nucleus. In: . [S.l.: s.n.], 1988. v. 168, n. 2, p. 463–467.

VASCONCELOS, F. F. et al. Artificial intelligence techniques empowered edge-cloud architecture for brain ct image analysis. *Engineering Applications of Artificial Intelligence*, Elsevier, v. 91, p. 103585, 2020.

VU, D.; GONZÁLEZ, R. G.; SCHAEFER, P. W. *Conventional MRI and MR angiography of stroke*. Springer, 2006. 115–137 p. Disponível em: <<http://www.mc.vanderbilt.edu/documents/NeuroICU/files/Conventional%20MRI%20and%20MRA.pdf>>. Acesso em: Fev. 2015.

WAJNGARTEN, M.; SILVA, G. S. Hypertension and stroke: update on treatment. *European Cardiology Review*, Radcliffe Cardiology, v. 14, n. 2, p. 111, 2019.

	INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA PARAÍBA
	Campus João Pessoa - Código INEP: 25096850
	Av. Primeiro de Maio, 720, Jaguaribe, CEP 58015-435, Joao Pessoa (PB)
	CNPJ: 10.783.898/0002-56 - Telefone: (83) 3612.1200

Documento Digitalizado Ostensivo (Público)

TCC assinado com a ficha catalográfica

Assunto:	TCC assinado com a ficha catalográfica
Assinado por:	Emanuel Silva
Tipo do Documento:	Tese
Situação:	Finalizado
Nível de Acesso:	Ostensivo (Público)
Tipo do Conferência:	Cópia Simples

Documento assinado eletronicamente por:

- Emanuel Thiago de Andrade da Silva, ALUNO (20182610001) DE BACHARELADO EM ENGENHARIA ELÉTRICA - JOÃO PESSOA, em 01/03/2024 15:18:44.

Este documento foi armazenado no SUAP em 01/03/2024. Para comprovar sua integridade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifpb.edu.br/verificar-documento-externo/> e forneça os dados abaixo:

Código Verificador: 1099688

Código de Autenticação: bf7e1122a1

