UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

CENTRO DE TECNOLOGIA

DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

Trabalho de Conclusão de Curso

ALGORITMO COMPUTACIONAL PARA SEGMENTAÇÃO DE TUMORES CEREBRAIS DO TIPO MENINGIOMA EM IMAGENS DE RESSONÂNCIA MAGNÉTICA

Beatriz Vasconcelos de Oliveira

Natal/RN

2024

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

CENTRO DE TECNOLOGIA

DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

ALGORITMO COMPUTACIONAL PARA SEGMENTAÇÃO DE TUMORES CEREBRAIS DO TIPO MENINGIOMA EM IMAGENS DE RESSONÂNCIA MAGNÉTICA

Trabalho de conclusão de curso apresentado ao Departamento de Engenharia Biomédica da Universidade Federal do Rio Grande do Norte para obtenção do título de Graduada em Engenharia Biomédica.

Graduanda: Beatriz Vasconcelos de Oliveira

Orientadora: Profª. Dra. Heliana Bezerra Soares

Natal/RN

2024

Universidade Federal do Rio Grande do Norte - UFRN
Sistema de Bibliotecas - SISBI
Catalogação de Publicação na Fonte. UFRN - Biblioteca Central Zila Mamede

Oliveira, Beatriz Vasconcelos de.
Algoritmo computacional para segmentação de tumores cerebrais do tipo meningioma em imagens de ressonância magnética / Beatriz Vasconcelos de Oliveira. - 2024.
62f.: il.

Monografia (graduação) - Universidade Federal do Rio Grande do Norte, Centro de Tecnologia, Curso de Engenharia Biomédica, Natal, 2024.
Orientação: Profª. Dra. Heliana Bezerra Soares.

1. Meningiomas - Monografia. 2. Imagens de ressonância magnética - Monografia. 3. Processamento digital de imagens - Monografia. I. Soares, Heliana Bezerra. II. Título.

RN/UF/BCZM CDU 537.635

Elaborado por Jackeline dos Santos Pinheiro da Silva Maia Cavalcanti - CRB-15/317

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

CENTRO DE TECNOLOGIA

DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

ALGORITMO COMPUTACIONAL PARA SEGMENTAÇÃO DE TUMORES CEREBRAIS DO TIPO MENINGIOMA EM IMAGENS DE RESSONÂNCIA MAGNÉTICA

Banca Examinadora do Trabalho de Conclusão de Curso:

Profª. Dra. Heliana Bezerra Soares _____

Orientadora

Profª. Dra. Caroline Dantas Vilar _____

Avaliadora Interna

Prof. Dr. Anthony Andrey Ramalho Diniz _____

Avaliador Externo

Natal/RN

2024

DEDICATÓRIA

Dedico este trabalho à minha mãe e irmã, que ao longo de toda a trajetória, sempre me apoiaram e incentivaram a finalizar esta jornada. E ao meu querido noivo, Alisson, que sempre acreditou em mim e nos meus sonhos.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por ter me capacitado e concedido forças para alcançar meus objetivos e ultrapassar todas as dificuldades encontradas ao longo do caminho.

A minha mãe, Paula, minha irmã, Natália e meu noivo Alisson, por sempre apoiarem as minhas decisões, acreditando em mim e fornecerem todo o suporte necessário para que eu concluísse esse sonho.

A minha orientadora Heliana, pelos ensinamentos ao longo do curso, que desde o tempo do grupo de pesquisa vem contribuindo para o desenvolvimento dos meus conhecimentos na área de processamento digital de imagens, e pela dedicação e paciência no meu processo de formação e elaboração deste trabalho.

Por fim, agradeço aos meus amigos, que fizeram parte deste caminho. Aqueles que estiveram presentes desde o curso de Ciência e Tecnologia, e aos meus amigos de trabalho, que sempre estavam me incentivando e torcendo para meu sucesso.

EPÍGRAFE

"O sábio nunca diz tudo o que pensa, mas pensa sempre tudo o que diz" (Aristóteles).

SUMÁRIO

LISTA DE FIGURAS x

LISTA DE TABELAS xii

LISTA DE ABREVIAÇÕES E SIGLAS xiii

RESUMO xiv

ABSTRACT xv

1. INTRODUÇÃO 1

1.1. OBJETIVOS 3

1.1.1. OBJETIVO GERAL 3

1.1.2. OBJETIVOS ESPECÍFICOS 3

1.2. ESTADO DA ARTE 3

1.3. ORGANIZAÇÃO DO TRABALHO 5

2 TUMORES CEREBRAIS: MENINGIOMA 6

3 PROCESSAMENTO DIGITAL DE IMAGENS 9

3.1 CONTEXTUALIZAÇÃO HISTÓRICA 9

3.2 RESSONÂNCIA MAGNÉTICA 10

3.3 CONCEITOS FUNDAMENTAIS 12

3.3.1. CÁLCULO DA MÉDIA DAS INTENSIDADES 13

3.3.2. MORFOLOGIA MATEMÁTICA 14

3.3.3. FILTROS PASSA-ALTA 15

3.3.4. SEGMENTAÇÃO: MÉTODO DE *K-MEANS* 16

4 ALGORITMO DE SEGMENTAÇÃO DE TUMORES CEREBRAIS 18

4.1 BASE DE DADOS 18

4.2 *MATLAB* 19

4.3 ALGORITMO DESENVOLVIDO 19

4.3.1. PRÉ-PROCESSAMENTO 20

4.3.2. SEGMENTAÇÃO 24

4.3.3. PÓS-PROCESSAMENTO 25

5 RESULTADOS E DISCUSSÕES 29

5.1 CORTE TRANSVERSAL 29

5.2 CORTE CORONAL 30

5.3 CORTE SAGITAL 30

5.4 DISCUSSÕES 31

6 CONCLUSÕES 35

6.1 TRABALHOS FUTUROS 35

6.2 CONTRIBUIÇÕES DO TRABALHO..... 36
7 REFERÊNCIAS BIBLIOGRÁFICAS 37
APÊNDICE A - APPLICATION OF DIGITAL IMAGE PROCESSING TECHNIQUES FOR SEGMENTATION OF MENINGIOMAS IN MAGNETIC RESONANCE IMAGES……..40

LISTA DE FIGURAS

Figura 1: Esquema básico para representação do sistema nervoso..... 6

Figura 2: (a) Meningioma na área parassagital e lobo frontal; (b) meningioma nos seios cavernosos e (c) meningioma no forame magno..... 8

Figura 3: Fluxograma dos processos de PDI e ADI..... 13

Figura 4: Representação de uma imagem no formato de matriz..... 14

Figura 5: (a) Representação da imagem original; (b) elemento estruturante; e (c) resultado após procedimento de erosão..... 15

Figura 6: (a) Imagem original da digital e (b) resposta ao filtro passa-alta com aguçamento dos contornos da imagem original..... 16

Figura 7: Representação do resultado da técnica de k-means aplicados aos pontos coloridos..... 17

Figura 8: (a) Imagem original e (b) máscara da segmentação dos especialistas..... 19

Figura 9: Técnicas de Processamento Digital de Imagens utilizadas no algoritmo..... 20

Figura 10: (a) Imagem original da base de dados e (b) remoção dos artefatos referentes a região craniana no corte transversal..... 21

Figura 11: (a) imagem original com média de intensidade entre 80 e 100; (b) primeira remoção craniana referente a imagem “a”; (c) segunda remoção craniana referente a imagem “a”; (d) imagem original com média de intensidade maior que 100; (e) primeira remoção craniana referente a imagem “d”; (f) segunda remoção craniana referente a imagem “d”..... 23

Figura 12: (a) imagem original de um corte coronal e (b) resultado do corte da região inferior..... 23

Figura 13: (a) Imagem original; Segmentação K-means: (b) Classe 1 - Centroide = 132.8939; (c) Classe 2 - Centroide = 0.0890; (d) Classe 3 - Centroide = 53.7483; (e) Classe 4 - Centroide = 41.9858..... 24

Figura 14: (a) Imagem original e (b) Pós-processamento com técnica de morfologia matemática..... 25

Figura 15: Diagrama de blocos da estratégia geral adotada para segmentação dos tumores do tipo meningioma conforme a média de intensidades e corte anatômico..... 26

Figura 16: Tela principal do sistema desenvolvido. (a) botão de pesquisa da imagem original, (b) definição do tipo de corte anatômico, (c) etapa de segmentação do tumor..27

Figura 17: Tela principal do sistema desenvolvido. (a) exibição da imagem original, (b) máscara de segmentação do especialista, (c) imagem após segmentação do sistema desenvolvido, (d) média das intensidades dos pixels e porcentagem de acerto..... 28

Figura 18: Resultado máximo de compatibilidade alcançado com a aplicação do algoritmo..... 32

Figura 19: Resultado para um corte transversal com presença de artefatos relacionados a olhos e região craniana..... 32

Figura 20: (a) Resultado para um corte coronal com a presença de artefatos relacionados a região craniana, ossos e músculos da face; e (b) Resultado para um corte sagital com a presença de artefatos relacionados a caixa craniana, pescoço e região do maxilar..... 33

Figura 21: (a) Resultado incorreto para um corte transversal; e (b) resultado incorreto para um corte coronal..... 34

LISTA DE TABELAS

Tabela 1: Tempos de relaxação T1 e T2 para diferentes tipos de tecidos considerando um campo de 1,5T..... 11

Tabela 2: Informações da base de dados contidas no *struct* 18

Tabela 3: Relação entre o valor da média de intensidades dos pixels e definição do filtro passa alta aplicado no sistema..... 22

Tabela 4: Resultados gerais e específicos para o corte transversal em tumores do tipo meningioma..... 30

Tabela 5: Resultados gerais e específicos para o corte coronal em tumores do tipo meningioma..... 30

Tabela 6: Resultados gerais e específicos para o corte sagital em tumores do tipo meningioma..... 31

LISTA DE ABREVIAÇÕES E SIGLAS

ADI - Análise Digital de Imagens

CAD - Sistema de auxílio diagnóstico (*Computer-aided diagnosis*)

CBTRUS - Central de Registro de Tumores Cerebrais dos Estados Unidos da América (*Central Brain Tumor Registry of the United States*)

CNN - Rede neural convolucional (*Convolutional Neural Networks*)

DLM - Modelo de aprendizado profundo (*Deep-learning model*)

ES - Elemento estruturante

IRM - Imagens de ressonância magnética

JPL - *Jet Propulsion Laboratory*

OMS - Organização Mundial da Saúde

PADI - Processamento e Análise Digital de Imagens

PDI - Processamento Digital de Imagens

RM - Ressonância magnética

ROI - Região de interesse (*Region of interest*)

RF - Pulso de radiofrequência

SNC - Sistema nervoso central

SNP - Sistema nervoso periférico

TC - Tomografia computadorizada

UI - *Interface* do usuário

OLIVEIRA, Beatriz Vasconcelos de. **Algoritmo computacional para segmentação de tumores cerebrais do tipo meningioma em imagens de ressonância magnética**. Trabalho de Conclusão de Curso, Graduação em Engenharia Biomédica, Universidade Federal do Rio Grande do norte, 62p., 2024.

RESUMO

Os tumores cerebrais são uma das diversas patologias associadas ao sistema nervoso, dentro das quais encontramos os meningiomas, que são um tipo de tumor cerebral derivado das meninges e que na maior parte dos casos são de procedência benigna. O padrão ouro para diagnóstico dessa doença ocorre através das imagens de ressonância magnética, exame importante para área médica visto que não utiliza radiação ionizante e gera imagens de qualquer região do corpo com um excelente padrão de visualização. Dessa forma, esse trabalho desenvolveu um algoritmo com o objetivo de auxiliar os profissionais da saúde na identificação e segmentação da região tumoral a partir de imagens de ressonância magnética e aplicando técnicas básicas de processamento digital de imagens. A base de dados utilizada fornece imagens em três tipos de corte: transversal, coronal e sagital. Portanto, foi traçado uma estratégia específica para cada tipo de imagem utilizando técnicas básicas de processamento de imagens, como: morfologia matemática, filtros no domínio da frequência e segmentação por *k-means*. A partir da extração da região de interesse, os resultados foram comparados com a máscara delimitada por especialistas a fim de validar os resultados encontrados. De forma geral o *software* apresentou respostas compatíveis para todos os tipos de imagens testadas, alcançando resultados superiores a 80% de acertos em relação a região correspondente do tumor.

Palavras-chave: meningioma, imagens de ressonância magnética, processamento digital de imagens, segmentação, filtros.

OLIVEIRA, Beatriz Vasconcelos de. **Computational algorithm for segmenting meningioma-type brain tumors in magnetic resonance images**. Trabalho de Conclusão de Curso, Graduação em Engenharia Biomédica, Universidade Federal do Rio Grande do norte, 62p., 2024.

ABSTRACT

Brain tumors are one of several pathologies associated with the nervous system, among we find meningiomas, which are a type of brain tumor derived from the meninges and in most cases are benign. The gold standard for diagnosing this disease is through magnetic resonance imaging, an important exam in the medical field since it does not use ionizing radiation and generates images of any region of the body with an excellent visualization standard. Thus, this work developed an algorithm to assist health professionals in identifying and segmenting the tumor region from magnetic resonance images and applying basic digital image processing techniques. The database used provides images in three types of sections: transverse, coronal and sagittal. Therefore, a specific strategy was outlined for each type of image using basic image processing techniques, such as: mathematical morphology, frequency domain filters and k-means segmentation. From the extraction of the region of interest, the results were compared with the mask delimited by experts in order to validate the results found. In general, the software presented compatible responses for all types of images tested, achieving results above 80% accuracy in relation to the corresponding region of the tumor.

Keywords: meningiomas, magnetic resonance imaging, digital image processing, segmentation, filters.

1. INTRODUÇÃO

Os tumores cerebrais correspondem a uma das diversas patologias do sistema nervoso, e podem ser divididos em duas categorias conforme a sua origem: tumores primários, provenientes do sistema nervoso central; ou secundários, derivados de outros tipos de câncer que sofrem metástase (CONTRERAS, 2017).

A Central de Registros de Tumores Cerebrais dos Estados Unidos da América (*Central Brain Tumor Registry of the United States* - CBTRUS), organização responsável por reunir os dados estatísticos referentes aos tumores do sistema nervoso central (SNC) no que diz respeito à população dos Estados Unidos da América, publicou em seu último relatório no período de 2013 a 2017, que a taxa de ocorrência dos tumores do SNC foi de 23,79%. Entre os tumores malignos mais recorrentes está o glioblastoma, correspondendo a 14,5%, enquanto o meningioma foi o mais comum entre os não malignos, com uma porcentagem de 38,3%. Outra característica relevante diz respeito ao acometimento dos meningiomas que apresentam maior incidência no sexo feminino. No mesmo período da coleta dos dados, foram registrados 81.246 casos de mortes relacionadas a tumores cerebrais e estimado um total de mais de 83.000 novos casos no ano de 2020 (OSTROM *et. al.*, 2020).

Em relação ao Brasil, segundo dados do INCA (2020), foram registrados 11.090 novos casos de tumores cerebrais do sistema nervoso central, com taxa de incidência para o Estado do Rio Grande do Norte correspondente a 5.17 e 3.87 por 100 mil habitantes, para homens e mulheres, respectivamente. O número de mortes por esta patologia ultrapassou os 9.000 casos no ano de 2020. Estes dados demonstram um fator de crescimento nos últimos anos, que estão associados com o envelhecimento da população e os avanços nas técnicas de diagnóstico por imagem (INCA, 2020).

O processamento digital de imagens vem se apresentando como uma ferramenta importante em várias áreas de atuação, sendo a saúde uma das mais relevantes, uma vez que sua utilização contribui com melhorias nas imagens radiográficas, o que facilita a interpretação das características de cada imagem pelos profissionais responsáveis (GONZALES E WOODS, 2010).

As técnicas de neuroimagens são a denominação atribuída ao conjunto de procedimentos referente a aquisição de imagens da região do cérebro através de exames

não invasivos, os quais são de extrema importância, uma vez que não oferecem riscos ao paciente e quando associados a outros dados clínicos podem auxiliar em um diagnóstico mais preciso e eficiente (MARTINEZ *et. al.*, 2014).

Os exames de imagem mais comuns para detecção de doenças neurológicas são a tomografia computadorizada (TC) e a ressonância magnética (RM). Estes permitem a visualização da área de interesse do cérebro através de imagens 2D, demonstrando a sua anatomia a partir de uma técnica não invasiva e aplicada *in vivo*, o que possibilita a análise do cérebro em atividade (MACHADO, 2014). Apesar desses métodos serem considerados o padrão ouro para diagnóstico da doença e delimitação da região de interesse (ROI), existem algumas limitações na sua aplicação de forma pura: não sendo possível definir o tipo e o grau de malignidade do tumor, por exemplo. Contudo, quando associada a outras estratégias mais recentes, tais limitações podem ser contornadas, contribuindo para o desenvolvimento de novas técnicas de diagnóstico (ARAGÃO E VALENÇA, 2010).

Os exames de imagem são analisados por médicos especialistas que delimitam a região tumoral através da visualização do exame e demarcação manual. Esta metodologia requer experiência do profissional e um olhar apto para identificação das patologias, com conhecimento aguçado de anatomia seccional, sugerindo assim que se trata de uma avaliação de difícil precisão e sujeita a falhas humanas naturais, devido à própria característica da imagem que possui níveis de intensidade muito próximos (MARTINEZ *et. al.*, 2014). Portanto, os sistemas de auxílio diagnóstico (CAD) são uma alternativa importante para apoiar os especialistas e diminuir a incerteza no momento em que o especialista for identificar o tumor e segmentar sua região de abrangência. Além de contribuir com o diagnóstico precoce, procedimento essencial nos índices de recuperação do paciente e resposta ao tratamento.

Com base no exposto acima, o trabalho tem como objetivo aplicar as técnicas de processamento digital de imagens para realizar a segmentação dos tumores cerebrais do tipo meningioma, extraindo as características da área encontrada em imagens de ressonância magnética (IRM), para apoiar o profissional especialista em sua análise e decisões acerca do caso de cada paciente.

1.1. OBJETIVOS

1.1.1. OBJETIVO GERAL

Desenvolver um algoritmo computacional para segmentação de tumores cerebrais do tipo meningioma em imagens de ressonância magnética, a partir da aplicação de técnicas básicas de processamento digital de imagens.

1.1.2. OBJETIVOS ESPECÍFICOS

1. Realizar um levantamento bibliográfico sobre o sistema nervoso e suas patologias, entendendo a neuroanatomia, a fisiologia e as principais características do tumor do tipo meningioma;

2. Selecionar a base de dados, analisar e escolher as imagens conforme conjunto de características pré-definidas, separando-as entre os três grupos tumorais existentes: meningiomas, gliomas e tumores pituitários;

3. Modelar o problema, criar uma estratégia e implementar de forma algorítmica;

4. Extrair as características significativas das imagens;

5. Realizar o teste da estratégia abordada em todas as imagens da base de dados;

6. Comparar os resultados do algoritmo com as imagens bases e analisar os padrões encontrados entre os três tipos distintos de tumores.

1.2. ESTADO DA ARTE

Soni e Rai (2021), propuseram a aplicação de processamento digital de imagens em exames de tomografia computadorizada do cérebro para identificação automática de tumores cerebrais. Entre as técnicas utilizadas estão: equalização de histograma, *thresholding*, filtro de reconhecimento de bordas Prewitt, operação de dilatação morfológica, preenchimento por inundação e extração da região de interesse. Para análise dos resultados os autores calculou a acurácia do sistema a partir das respostas de 52 imagens da base de dados, que eram caracterizadas por aquelas que apresentavam tumor e outras com cérebro saudável, obtendo um valor de 94,23%.

Mascarenhas *et al.* (2020) utilizaram métodos computacionais para identificação de câncer cerebral em imagens de ressonância magnética, a fim de segmentar a região de interesse correspondente aos tumores. Neste estudo foram abordadas imagens com planos de corte anatômicos distintos e para comparação dos resultados, dois especialistas

avaliaram os exames e realizaram a sua segmentação manual. Dessa forma, os algoritmos compreendiam técnicas de correção de contraste, normalização de histograma, binarização, segmentação e morfologia matemática. Os resultados alcançados mostraram uma porcentagem de acerto de 89,23%.

Zulkoffli e Shariff (2019), apresentaram um sistema de identificação automática de tumores cerebrais em IRM, no qual foram aplicados os passos essenciais para o processamento digital das imagens: pré-processamento e pós-processamento. Entre as características obtidas estavam: contraste, energia, correlação, homogeneidade, área e perímetro. Após os testes, o algoritmo acertou cerca de 60% das imagens testadas, entre as quais demonstraram uma precisão de 91,65% na localização dos tumores.

Rasool *et. al*. (2022), propuseram uma arquitetura híbrida baseada em Rede Neural Convolucional (CNN) com o objetivo de classificar tumores dos tipos glioma, meningioma e tumor hipofisário a partir de imagens de ressonância magnética. Nesse estudo foram desenvolvidos dois modelos híbridos, um que combinou Google-Net com SVM, denominado GN-SVM, outro combinando Google-Net com ajuste fino, conhecido como GN-FT. Os pesquisadores utilizaram a mesma base de dados deste trabalho, dividindo-a em grupos de treinamento, correspondente a 80%, e imagens para teste, em uma proporção de 20%. Os resultados obtidos foram considerados eficientes e apresentaram valor de precisão de 98,1% para o método GN-SVM, e 93,1% para o GN-FT.

Laukamp *et al*. (2018), abordaram o uso de um modelo multiparamétrico de aprendizado profundo (DLM) em imagens de ressonância magnética, a fim de verificar o desempenho desse modelo na detecção e segmentação de meningiomas quando comparados com a máscara dos especialistas. Os exames de imagem passaram por um pré-processamento antes de serem aplicados na segmentação automática. O DLM foi fundamentado na arquitetura DeepMedic com uso de uma rede convolucional 3D profunda. Em relação a detecção do tumor, a precisão do sistema alcançou a porcentagem de 98%. Porém, as respostas das segmentações apresentaram uma variedade conforme o grau da lesão e localização do tumor.

O estudo base apresentou 66% de acerto na localidade do tumor, enquanto este trabalho chegou a porcentagens superiores, com cerca de 80% de precisão. Além disso, os valores de acerto considerados aceitáveis saíram de 49% para 54% de correspondência.

1.3. ORGANIZAÇÃO DO TRABALHO

Inicialmente, a seção 1 abrange uma breve introdução sobre o tema, a problemática e justificativa do trabalho, assim como os objetivos gerais e específicos. A seção 2 descreve conceitos sobre o sistema nervoso, características do tumor cerebral do tipo meningioma e aplicação das tecnologias de imagem dentro dessa área. A seção 3, aborda uma breve contextualização histórica sobre as imagens digitais, os conceitos de processamento digital de imagens utilizados nesse trabalho e a explicação sobre o funcionamento da ressonância magnética. A seção 4 explica todo o sistema desenvolvido, explicitando a estratégia adotada e mostrando os resultados referentes a cada passo. A seção 5 apresenta os testes e resultados alcançados. Na seção 6 são apresentadas as conclusões e perspectivas de trabalhos futuros.

2. TUMORES CEREBRAIS: MENINGIOMA

Os tumores do sistema nervoso central são considerados a segunda maior causa de óbitos quando tratamos de doenças neurológicas, ficando atrás apenas dos acidentes vasculares cerebrais. Esses tipos de tumores podem acontecer em qualquer faixa etária e em diversas localidades do cérebro (MENDES *et. al.*, 2014). Porém, se apresentam com maior incidência em indivíduos acima de 65 anos e do sexo feminino. Além disso, os dados referentes aos casos de tumores cerebrais estão aumentando ao longo dos anos, o que pode estar relacionado ao envelhecimento da população e melhorias constantes nos exames de imagem que detectam esse tipo de patologia (MAROSI *et. al.*, 2008).

Para compreender melhor os tumores cerebrais, devemos conhecer as características anatômicas gerais do sistema nervoso. Esse sistema é formado pelo sistema nervoso central (SNC) e sistema nervoso periférico (SNP) (Figura 1). O objeto de estudo foi situado no sistema nervoso central, que por sua vez está composto pelo encéfalo e medula espinhal, sendo o encéfalo formado pelo cérebro e cerebelo (MACHADO, 2014).

Figura 1: Esquema básico para representação do sistema nervoso.

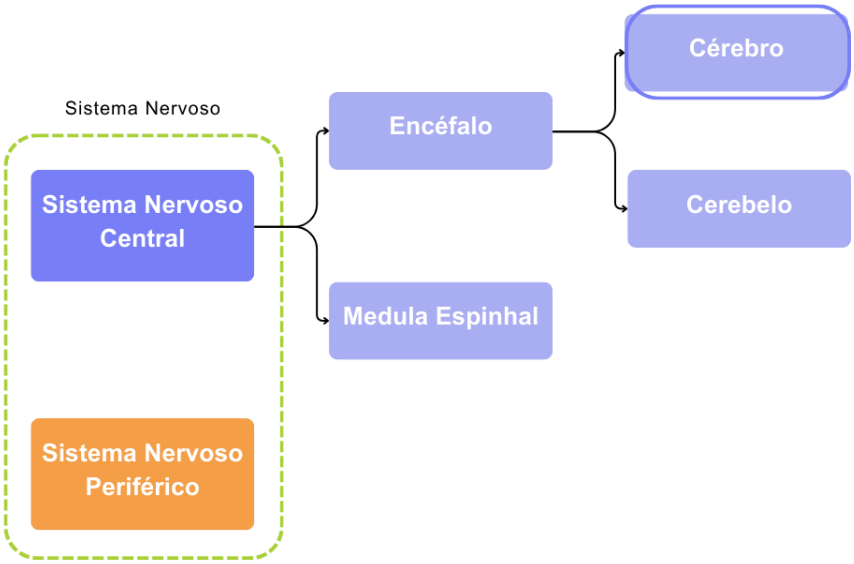

Fonte: adaptado de Machado, 2014.

O cérebro está revestido por uma camada chamada meninge, por sua vez formada pela união de três membranas: dura-máter, aracnóide e pia-máter. A principal função da meninge, proteger a região cerebral, contudo, esta pode sofrer com algumas patologias relacionadas tanto a infecções na forma de meningite, quanto a tumores cerebrais. Dessa forma, o nome meningioma está diretamente associado a esta camada importante de

proteção (MACHADO, 2014).

Visando a regulamentação da gravidade dos tumores do cérebro, a Organização Mundial da Saúde (OMS) definiu em 2007 quatro subgrupos que compreendem os níveis das lesões cerebrais (LOUIS *et. al.*, 2007):

- Grau I: lesões não infiltrativas, com baixo potencial proliferativo, sem atipias nucleares, mitoses, proliferação endotelial ou necrose.
- Grau II: lesões em geral infiltrativas, com atipias nucleares e baixo índice mitótico, sem proliferação endotelial ou necrose.
- Grau III: lesões infiltrativas, com dois critérios presentes, em geral atipias nucleares e alto índice mitótico.
- Grau IV: lesões infiltrativas, com três ou quatro critérios presentes.

A partir da definição determinada pela OMS, podemos destacar que os meningiomas são tumores que apresentam na maior parte dos casos característica de benignidade, se enquadrando na categoria de grau I. Entretanto, existem casos que são considerados atípicos ou de grau II, além dos anaplásicos ou malignos de grau III ou superior (MENDES *et. al.*, 2014).

No que diz respeito a localidade desses tumores, devido a sua derivação ocorrer geralmente a partir de células da capa aracnóide, podem ser encontrados em qualquer região do crânio. Algumas das áreas mais comuns de incidência são a área parassagital (Figura 2(a)), seios cavernosos (Figura 2(b)) e o forame magno (Figura 2(c)). Sendo estatisticamente os meningiomas parassagitais aqueles de maior incidência, cerca de 20%, aparecendo com maior frequência no lobo frontal (MAROSI *et. al.*, 2008).

Figura 2: (a) Meningioma na área parassagital e lobo frontal; (b) meningioma nos seios cavernosos e (c) meningioma no forame magno.

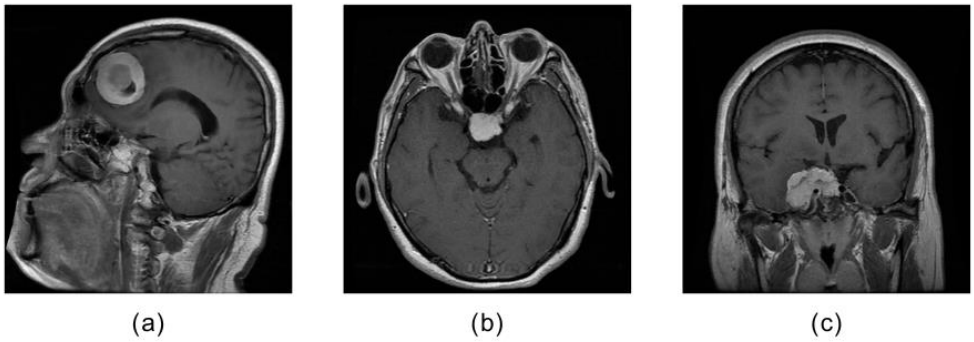

Fonte: adaptado da base de dados, Cheng *et. al.*, 2015.

Independente da área afetada, os sintomas mais comuns acontecem devido à compressão dos sistemas adjacentes e acarretam dores de cabeça, alterações mentais, convulsões e problemas nos sentidos da visão e audição, por exemplo. Entretanto, com o avanço das tecnologias de imagens, muitas vezes a patologia foi encontrada antes mesmo de qualquer um desses sintomas serem expressos, ou seja, podendo ser identificada ainda em um estágio inicial, o que contribui significativamente para o sucesso do tratamento (MAROSI *et. al.*, 2008).

No que diz respeito ao tratamento, a técnica de remoção cirúrgica ainda foi considerada o padrão ouro para esse tipo de patologia e tem uma alta taxa de sucesso. A radioterapia é uma alternativa menos utilizada, visto que grande parte dos meningiomas são de procedência benigna, entretanto, esta opção acaba sendo mais utilizada em tumores malignos ou que apresentam reincidência após a prática cirúrgica (MAROSI *et. al.*, 2008).

As técnicas de imagem são empregadas durante todo o processo, desde a descoberta da doença até o tratamento e acompanhamento clínico do paciente. Além da detecção inicial de que o indivíduo possui o tumor, as imagens funcionam como guia para as técnicas de neurocirurgias atuais, contribuindo para a remoção completa da região afetada. Quando nos referimos à prática da radioterapia os exames de imagem também são de grande importância, visto que definem a área alvo de irradiação (MAROSI *et. al.*, 2008).

3. PROCESSAMENTO DIGITAL DE IMAGENS

3.1. CONTEXTUALIZAÇÃO HISTÓRICA

O processamento de imagens teve início com a implementação do sistema *Bartlane* ainda no início do século passado, em que as imagens eram transmitidas através de cabos submarinos, que cruzavam o oceano ligando Londres a Nova York, devido à necessidade de transmissão das informações de forma mais rápida, com o objetivo de melhorar a comunicação entre países distantes. O novo sistema alcançava seu objetivo em menos de três horas, o que resultava em uma redução no tempo de transmissão que antes correspondia a mais de uma semana. Inicialmente estas imagens eram codificadas com apenas cinco níveis de intensidade e chegaram à codificação com quinze níveis de intensidade cerca de trinta anos depois (MARQUES E VIEIRA, 1999).

Anos depois, o grande ápice no processamento digital de imagens ocorreu com a modernização dos computadores e aumento da capacidade de processamento, sendo o projeto de maior destaque para o conhecimento da área desenvolvido no *Jet Propulsion Laboratory* (JPL) dos Estados Unidos da América, o qual estava diretamente associado com o programa espacial norte-americano e possibilitou a correção para melhor visualização de imagens da lua (GONZALES E WOODS, 2010).

Após estes dois pontos cruciais na história, outras áreas do conhecimento desenvolveram a utilização de imagens digitais para aprimorar suas abordagens, como por exemplo, a área de geografia, sensoriamento remoto e meteorologia, principalmente através das imagens obtidas por satélite. Atualmente tais métodos são aplicados em outras áreas além daquelas citadas anteriormente, como: segurança, a indústria em linhas de produção, restauração de fotos antigas, a crescente demanda no uso de robôs e transportes autônomos que requerem uma visão artificial aguçada, são alguns dos exemplos mais comuns (MARQUES E VIEIRA, 1999).

Ainda na década de 60, houve um grande crescimento e aplicação das técnicas de processamento de imagens na área da saúde, uma vez que os exames de imagem se tornaram cada vez mais comuns e ferramentas indispensáveis tanto para auxiliar no diagnóstico médico quanto nas terapias que são guiadas por imagem, ou seja, passaram a influenciar de forma direta nas decisões terapêuticas que seriam adotadas (GONZALES E WOODS, 2010).

Dessa forma, atualmente a área médica no que diz respeito às imagens digitais apresenta uma grande necessidade de processamento das informações tanto para facilitar a interpretação humana, quanto para armazenamento e análise dos dados através de inteligência artificial (GONZALES E WOODS, 2010). Na atualidade a aplicação dessas técnicas de forma integrada se tornou uma grande aliada da medicina e dos profissionais da saúde.

3.2. RESSONÂNCIA MAGNÉTICA

Os exames de imagem por ressonância magnética foram criados em meados dos anos 70 de forma simultânea às imagens de tomografia computadorizada. A IRM é um dos métodos mais difundidos na atualidade, principalmente devido a sua abordagem não invasiva, associado ao fato de não ser necessário a submissão do paciente à radiação ionizante (MADUREIRA *et. al.*, 2010).

No início do ano de 2024 aconteceu mais um avanço nesta área imprescindível para a medicina. Recentemente pesquisadores conseguiram obter imagens de ressonância magnética de um equipamento que chegou ao alcance de 11.7 Teslas. Segundo a France Presse: “Essa potência permite que a máquina escanei imagens 10 vezes mais precisas do que os aparelhos normalmente utilizados em hospitais – cuja potência geralmente não supera os três teslas” (FRANCE PRESSE, 2024). A ressonância magnética continua evoluindo constantemente no que diz respeito à qualidade da imagem e tempo de resposta do exame, o que acrescenta cada vez mais valor à sua aplicação clínica.

A ressonância diz respeito a uma propriedade da matéria em que os átomos entram em movimento de precessão quando submetidos a um campo magnético. Uma das características facilitadoras da aplicação dessa propriedade na aquisição de imagens do corpo humano diz respeito ao átomo de hidrogênio, um dos elementos mais abundantes no nosso sistema corporal. Devido a sua característica de apresentar apenas um próton e um nêutron em seu núcleo, a reação dessa partícula a um campo magnético externo apresenta respostas no que diz respeito a movimentação em torno de seu próprio eixo e que são extremamente significantes quando comparadas a outros átomos presentes no corpo. Outro aspecto fundamental do átomo de hidrogênio diz respeito a reação que deriva do fenômeno de ressonância e demonstra diferenças significativas entre a resposta de tecidos normais e tecidos patológicos (MAZZOLA, 2009).

O movimento que o átomo exerce em torno de seu próprio eixo, denominamos *spin* magnético, o que leva esta partícula a responder como uma espécie de ímã. A partir desta propriedade, ao ser inserido em um campo magnético externo, o átomo tende a se alinhar tanto para o lado positivo deste campo, quanto para o negativo. Portanto, anulando as suas forças. Contudo, alguns átomos ainda prevalecem e não sofrem anulação em relação aos demais (GROVER *et. al.*, 2015).

Os átomos que permanecem em movimento de precessão irão compor o vetor magnetização resultante e para detectar o sinal deste componente, aplicamos um pulso de radiofrequência (RF) que deve estar situado de forma perpendicular ao plano transversal e induzindo o vetor magnetização a sofrer um desvio de 90°, portanto, o torna alinhado no plano transversal. Ao término da aplicação da RF o sinal retorna a sua posição de origem, movimento este conhecido como relaxação, sendo que o tempo necessário para completar este movimento corresponde ao tempo de relaxação, representado por duas variáveis de tempo: T1 e T2 (MAZZOLA, 2009).

A partir dessa propriedade de relaxação, podemos extrair um atributo muito importante, onde cada tecido apresenta um tempo de relaxação diferente, gerando assim um contraste entre os diversos tecidos presentes na imagem e consequentemente nos permitindo diferenciar os tipos de tecidos (Tabela 1) (MAZZOLA, 2009).

Tabela 1: Tempos de relaxação T1 e T2 para diferentes tipos de tecidos considerando um campo de 1,5 T.

Tecido	T1(ms)	T2(ms)
Substância branca	790	90
Substância cinzenta	920	100
Líquido céfalo-raquidiano (líquor)	4000	2000
Sangue (arterial)	1200	50
Parênquima hepático	490	40
Miocárdio	870	60
Músculo	870	50
Lipídios (gordura)	260	80

Fonte: Mazzola, 2009.

O exame de IRM nos permite selecionar o local do corpo desejado para análise com precisão. Na reconstrução da imagem são usadas uma sequência de cortes da área almejada, formado por projeções 2D e conhecidos como *slices*. Esse recorte preciso e

bem localizado decorre de um conjunto de campos magnéticos auxiliares ao principal, denominados campos gradiente (GROVER *et. al.*, 2015).

Após o sinal de cada corte ser devidamente armazenado, aplicamos a Transformada de Fourier para que os dados enfim sejam transformados, passando do domínio do tempo para o domínio das frequências (MAZZOLA, 2009).

Na década passada a IRM abordava apenas regiões do corpo específicas, devido ao longo período necessário para realização dos exames em que os pacientes tinham que permanecer imóveis, então, alternativas como tomografia computadorizada e radiografia eram tidas como opção. Porém, com todo avanço tecnológico esse tempo de espera se torna cada vez menor, possibilitando que o exame de ressonância tenha uma abrangência cada vez maior e seja aplicado a diversos sistemas do corpo, como: sistema cardiovascular, respiratório, nervoso, musculoesquelético, até mesmo os órgãos dos sentidos (MADUREIRA *et. al.*, 2010).

3.3. CONCEITOS FUNDAMENTAIS

As imagens digitais para análise computacional são representadas na forma de matrizes através de uma função bidimensional $f(x,y)$ na forma contínua, sendo x e y a representação das coordenadas de cada ponto e a função f representa o valor de intensidade daquela posição específica. Cada elemento representado por sua respectiva posição na matriz corresponde ao componente elementar das imagens, denominado *pixel* (QUEIROZ E GOMES, 2001).

Segundo Gonzales e Woods (2010) o processamento de imagens pode ser distinguido em três tipos de processos computacionais: nível baixo, médio e alto. Os de baixo nível se enquadram no pré-processamento das imagens, com o objetivo de aplicar técnicas que melhorem a qualidade da imagem de entrada. As técnicas de nível médio por sua vez fazem a distinção e aquisição de características das imagens de entrada, sendo o processo mais comum a segmentação, que fornece informações sobre bordas ou identificação de objetos que compõem a imagem original. Por último, os processos de alto nível estão relacionados à interpretação das informações obtidas na etapa anterior.

De maneira semelhante, Viana *et. al.* (2017) aborda o conceito de Processamento e Análise Digital de Imagens (PADI) que é a união das técnicas de Processamento Digital

de Imagens (PDI) e Análise Digital de Imagens (ADI). Na perspectiva do PDI as imagens são tratadas através de operações matemáticas aplicadas diretamente sobre cada *pixel*, deixando a imagem preparada para uma análise por meio do ADI. O fluxograma a seguir, Figura 3, apresenta essa distinção entre as técnicas e seus respectivos processos.

Figura 3: Fluxograma dos processos de PDI e ADI

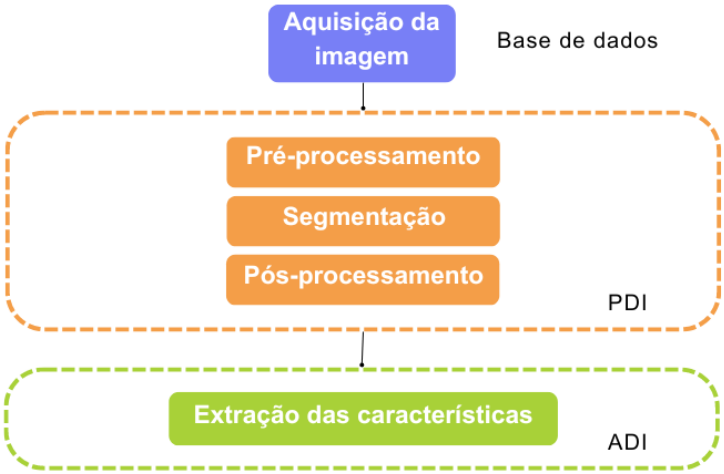

Fonte: autoria própria.

Neste tópico abordaremos os conceitos referentes às técnicas aplicadas na estratégia algorítmica pensada para este projeto. Vale ressaltar que tais procedimentos se encaixam apenas no que se refere às técnicas de Processamento Digital de Imagens, que foram propositalmente escolhidas para verificar o comportamento de tais métodos em IRM e avaliar os resultados obtidos com a aplicação dessas ferramentas mais básicas.

3.3.1. CÁLCULO DA MÉDIA DAS INTENSIDADES

Cada imagem pode ser representada por uma matriz e tem como elemento fundamental o *pixel*. A partir dessa definição podemos entender como realizar operações matemáticas com essas figuras, onde a operação que relaciona uma ou mais imagens é executada de forma individual entre os *pixels* nas posições correspondentes (GONZALES E WOODS, 2010).

Dessa forma, para calcular a média das intensidades presentes em cada exame, foi realizado o somatório do valor de intensidade de cada *pixel* e dividido pela quantidade total de *pixels* da imagem completa, encontrado a partir da multiplicação M x N, onde M corresponde ao número de linhas e N ao número de colunas, Figura 4.

Figura 4: Representação de uma imagem no formato de matriz.

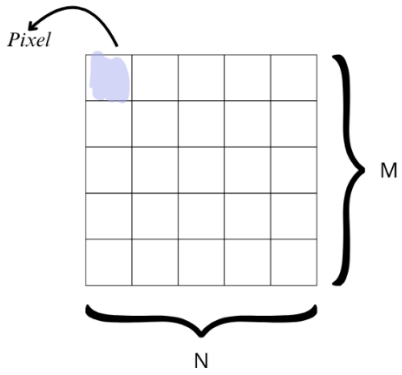

Fonte: autoria própria.

Uma vez realizada a operação matemática, conseguimos inferir algumas características correspondentes a cada imagem. Sabendo que a escala de intensidades de uma imagem em níveis de cinza vai de 0 - preto a 255 - cinza, quando a média apresentar um valor mais elevado, foi considerado que esta imagem tem uma maior quantidade de tons de branco. De forma semelhante acontece com o oposto, quanto menor for o valor de média, mais próximo de preto estão os *pixels* deste exame.

3.3.2. MORFOLOGIA MATEMÁTICA

Como o próprio nome sugere, morfologia remete a forma e estrutura de algum objeto. No nosso caso, essa técnica importante tem maior usabilidade durante o pré ou pós-processamento, com o objetivo principal de destacar e representar uma região no que diz respeito à sua forma ou bordas (GONZALES E WOODS, 2010).

Para que seja possível realizar as operações morfológicas a imagem deve ser percorrida por um elemento estruturante (ES), Figura 5(b). Esse elemento tem uma variedade de formas possíveis, como diamante, disco, retângulo, octágono, linha ou quadrado (*MathWorks*, 2024). Uma vez definida qual forma será utilizada, o componente irá percorrer cada parte da imagem (Figura 5(a)) através da sua posição central, representada pelo ponto na Figura 5(b), e observando se o ES está totalmente contido dentro da região analisada, caso não esteja os *pixels* correspondentes serão eliminados, configurando assim o processo de erosão, que se caracteriza pela diminuição da região de interesse, Figura 5(c) (GONZALES E WOODS, 2010).

Figura 5: (a) Representação da imagem original; (b) elemento estruturante; e (c) resultado após procedimento de erosão.

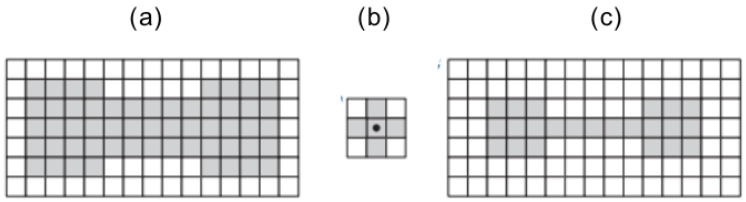

Fonte: adaptado de Gonzales e Woods, 2010.

Para entender o processo de fechamento necessitamos explicar um pouco sobre a dilatação, que por sua vez tem como objetivo aumentar a área da região de interesse. Neste caso, o deslocamento do ES em torno do conjunto da imagem original traz como premissa que pelo menos uma parte do elemento esteja sobreposto com a região analisada. Dessa forma, todo o restante do espaço será automaticamente preenchido, gerando assim a dilatação (MARQUES E VIEIRA, 1999).

A técnica de fechamento também pertence às operações morfológicas, porém desta vez seu objetivo concerne em preencher os buracos e desfazer as descontinuidades existentes tanto no centro quanto nas extremidades da região de interesse. Este processo reúne os dois passos aprendidos previamente, tratando de uma sequência de dilatação da imagem original seguida pela etapa de erosão do resultado anterior (MARQUES E VIEIRA, 1999).

3.3.3. FILTROS PASSA-ALTA

No âmbito do estudo das técnicas de filtragem, teremos as filtragens no domínio espacial e no domínio da frequência. Além disso, nos dois casos temos filtros que são denominados de passa-baixa e passa-alta. Para este trabalho, foram utilizados os filtros no domínio da frequência, bem como aqueles caracterizados como passa-alta.

No domínio da frequência podemos relacionar as intensidades de cada *pixel* com as frequências encontradas a partir da Transformada de Fourier, onde as baixas frequências condizem com mudanças suaves de intensidade, enquanto as altas frequências caracterizam regiões de mudança abruptas de intensidade, como bordas. Assim observamos no exemplo da Figura 6, a representação do aguçamento dos contornos da imagem da digital após aplicação da filtragem passa-alta. Após a análise no

que diz respeito às frequências, para obter um resultado no domínio da imagem novamente, realizamos a Transformada Inversa de Fourier (SHAIKH *et. al.*, 2016).

Figura 6: (a) Imagem original da digital e (b) resposta ao filtro passa-alta com aguçamento dos contornos da imagem original.

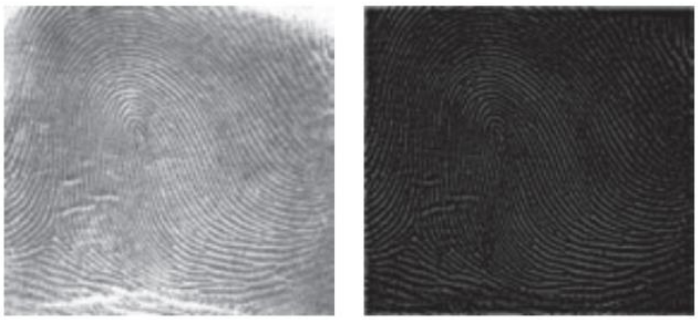

Fonte: adaptado de Gonzales e Woods, 2010.

Levando em consideração que a filtragem passa-alta mantém as frequências altas, que estão diretamente relacionadas com o contorno da região de interesse, e inibe aquelas frequências mais baixas. Podemos considerar que na utilização de um filtro passa-alta as bordas ou mudanças bruscas de intensidades serão realçadas (MARQUES E VIEIRA, 1999). Dessa forma, utilizamos dois filtros característicos dessa propriedade, o Butterworth e o Gaussiano.

3.3.4. SEGMENTAÇÃO: MÉTODO DE *K-MEANS*

A segmentação pode ser considerada um dos passos mais importantes no nosso processo algorítmico, tendo como objetivo distinguir a imagem em regiões menores que caracterizam partes do todo. O resultado obtido nesta etapa será determinante para o sucesso ou falha do processo, visto que a resposta final trata do produto desta segmentação.

O método de *k-means* segue um passo a passo bem definido. De forma geral, ele agrupa os pontos analisados dentro de grupos menores a partir do valor do centróide de cada subdivisão. Dessa forma, o primeiro passo consiste em definir a quantidade de *clusters*, que são a quantidade de grupos formados ao final do processo. Em seguida, os valores dos centróides podem ser pré-definidos ou gerados aleatoriamente, e assim usados para calcular a distância de cada ponto até o seu centróide mais próximo. A partir deste momento, o algoritmo irá recalcular o valor do centróide com a média dos elementos que

fazem parte daquele grupo específico, então a operação de verificação das distâncias acontece diversas vezes até que o algoritmo chegue em uma convergência (MENDES JÚNIOR, 2015).

Alcançamos a convergência quando após a execução do algoritmo nenhum ponto sofre alteração de grupo, visto que a cada execução o método de *k-means* tenta minimizar a distância entre os padrões dos grupos. Então, teremos como resultado uma quantidade de segmentações correspondente à quantidade de *clusters* definidas no início, ou seja, uma quantidade de objetos de interesse retirados da imagem original (MENDES JÚNIOR, 2015).

Para exemplificar a técnica de *k-means* podemos observar a Figura 7, onde temos como resposta ao final da execução do algoritmo, três grupos: G1, G2 e G3, que por sua vez englobam os respectivos pontos calculados como os mais próximos daquela região específica. A quantidade de grupos igual a 3 corresponde ao valor de *cluster* definido inicialmente e cada estrela colorida representa um centroide.

Figura 7: Representação do resultado da técnica de k-means aplicados aos pontos coloridos.

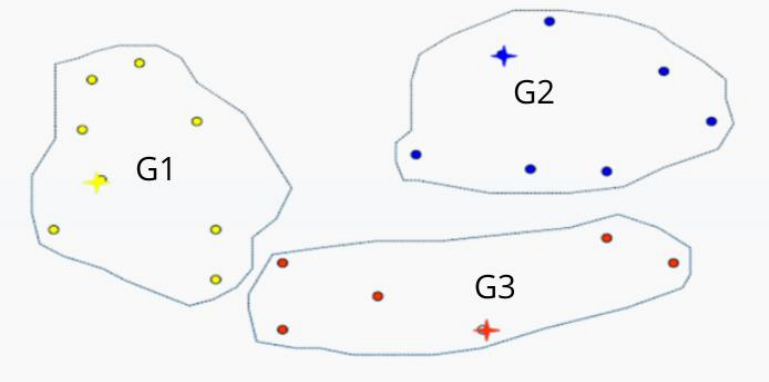

Fonte: adaptado de Mendes Júnior, 2015.

4. ALGORITMO DE SEGMENTAÇÃO DE TUMORES CEREBRAIS

4.1. BASE DE DADOS

As imagens utilizadas neste trabalho estão disponíveis em uma base de dados de distribuição aberta e podem ser acessadas de forma *online*, tanto através do repositório *Figshare* quanto na plataforma de hospedagem *Github*. A aquisição das imagens aconteceu no período de 2005 a 2010, no *Nanfang Hospital - Guangzhou* e *General Hospital - Tianjing Medical University*, ambos localizados na China (CHENG *et. al.*, 2015).

A base de dados foi composta por imagens de ressonância magnética da região do cérebro ponderadas em T1 e estão subdivididas em três categorias de tumores cerebrais: meningiomas, gliomas e tumores pituitários. O conjunto de dados possui um total de 3061 *slices* referente a 233 pacientes, sendo: 705 de meningiomas, 1426 de gliomas e 930 de tumores pituitários (CHENG *et. al.*, 2015). Além da abrangência de três tipos de tumores, temos no banco de dados uma variação dentro das imagens no que diz respeito aos cortes anatômicos, sendo: coronal, sagital e transversal.

As informações referentes a cada exame estão contidas dentro de um *struct* com a extensão *.mat* e incluem a identificação do tumor, o código de identidade do paciente, a imagem original em forma de matriz, um vetor de coordenadas e uma máscara do tumor, como descrito na Tabela 2.

Tabela 2: Informações da base de dados contidas no *struct*.

Variável	Descrição
cjdata.label	Identificação do tumor: (1) Meningioma, (2) Glioma e (3) Tumor Pituitário
cjdata.PID	Identificação do paciente
cjdata.image	Imagem original da ressonância magnética
cjdata.tumorBorder	Vetor descrevendo as coordenadas das bordas do tumor
cjdata.tumorMask	Imagem binária da região do tumor

Fonte: autoria própria**.**

Inicialmente as imagens da base de dados estavam na forma matricial, porém, para facilitar a manipulação e aplicação das técnicas foi necessário realizar a conversão das matrizes referentes às imagens originais (Figura 8(a)) e máscaras dos especialistas (Figura 8(b)) para o formato *.png*, o que ajudou tanto no processamento quanto na melhor visualização dos exames.

Figura 8: (a) Imagem original e (b) máscara da segmentação dos especialistas.

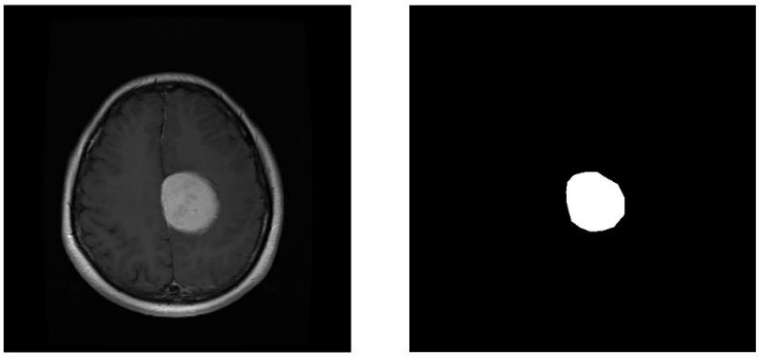

Fonte: adaptado da base de dados, Cheng *et al.*, 2015.

As informações correspondentes à identificação do tumor e máscara delimitada pelo especialista, que estão contidas na base de dados, foram utilizadas posteriormente na avaliação dos resultados.

4.2. *MATLAB*

O *MATLAB* consiste em um *software* de desenvolvimento que utiliza uma linguagem de programação baseada em matrizes e matemática computacional, aplicada principalmente nas áreas de engenharia e ciência para análise de dados e sistemas. A aplicação dessa ferramenta abrange desde a área acadêmica até o setor industrial, com projetos que incluem processamento de imagens e visão computacional, processamento de sinais, biologia computacional, sistemas de controle e aprendizagem profunda (*MathWorks*, 2022).

Este *software* demonstra ser de fácil aplicação quando comparado a outros sistemas de desenvolvimento como linguagens de programação mais complexas, uma vez que dispõe de ferramentas auxiliares que potencializam o desempenho dos algoritmos, como a *Image Processing Toolbox* que incrementa os fluxos de atividades essenciais para o processamento digital de imagens bidimensionais e tridimensionais, refinando os resultados desde o processamento até a manipulação das regiões de interesse.

4.3. ALGORITMO DESENVOLVIDO

A estratégia utilizada na criação do algoritmo foi totalmente desenvolvida no *software MATLAB* na versão R2020a e tem como objetivo implementar técnicas de processamento digital de imagens através de um algoritmo para analisar imagens de

ressonância magnética, a fim de identificar as regiões que correspondem a tumores cerebrais do tipo meningioma e segmentá-las, auxiliando dessa forma o profissional especialista na localização e delimitação das bordas do tumor.

Para este trabalho, as técnicas utilizadas (Figura 9) foram inseridas dentro dos processos computacionais de nível baixo e médio relacionadas ao Processamento Digital de Imagens. No que se refere aos métodos de baixo nível ou pré-processamento, estão a aplicação de morfologia matemática para remoção dos artefatos cranianos, cálculo da média de intensidades e aplicação de filtros passa alta. Em relação às técnicas de nível médio utilizamos a segmentação, seguido da morfologia matemática como recurso para o pós-processamento.

Figura 9: Técnicas de Processamento Digital de Imagens utilizadas no algoritmo.

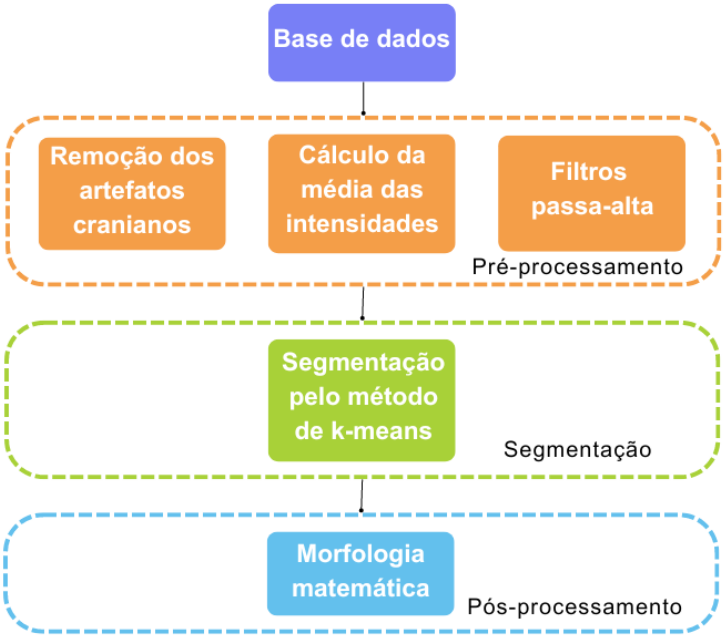

Fonte: autoria própria.

4.3.1. PRÉ-PROCESSAMENTO

Iniciamos com uma avaliação das imagens presentes na base de dados (Figura 10(a)) e a tentativa de aplicar a segmentação de forma direta no exame, identificamos que a caixa craniana se apresentava como um artefato, dificultando que a operação de segmentação do tumor fosse bem-sucedida. Dessa forma, com o objetivo de contornar esse obstáculo, realizamos a remoção dessa região por não fazer parte da área de interesse do estudo por meio da morfologia matemática (Figura 10(b)), aplicando a técnica de erosão com elemento estruturante no formato de disco com raio 30.

Figura 10: (a) Imagem original da base de dados e (b) remoção dos artefatos referentes a região craniana no corte transversal.

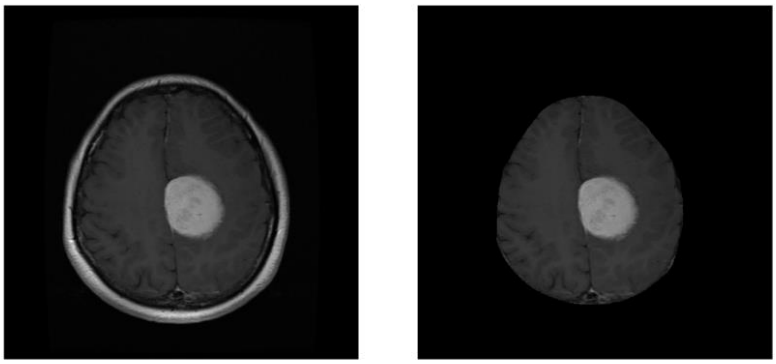

(a) (b)

Fonte: autoria própria.

Realizada a estratégia de remoção do crânio, aplicamos a filtragem passa alta levando em consideração que o conjunto de componentes de alta frequência em uma imagem corresponde a alterações abruptas de intensidade, inclusive caracterizando regiões de borda. Portanto, o filtro passa-alta pode ser aplicado para ressaltar essas informações, visto que sua aplicação atenua as baixas frequências sem interferir nas altas frequências (GONZALES E WOODS, 2010).

Assim, as técnicas de filtragem empregadas foram definidas a partir da análise das intensidades de cada *pixel*, através do cálculo da média de intensidade para cada imagem de forma individual, associado ao corte anatômico correspondente, pois os filtros escolhidos não apresentavam um comportamento homogêneo para todas as imagens testadas. Para determinar qual estratégia seguir e como as variações de intensidade afetam cada técnica, foram analisadas inicialmente um total de 100 (cem) exames, observando as respostas de dois tipos de filtro passa alta aplicados na imagem pré-processada, os filtros Gaussiano e Butterworth.

O conjunto de teste trouxe perfis de comportamento diferentes para a resposta dos filtros em relação ao intervalo definido de média, obtendo como valor final os índices destacados na Tabela 3, seguidos dos filtros que apresentaram melhores resultados conforme a média das intensidades.

Tabela 3. Relação entre o valor da média de intensidades dos *pixels* e definição do filtro passa alta aplicado no sistema.

Média de intensidade dos *pixels*	**Filtro passa alta**
Média < 63	Filtro Gaussiano
63 < Média < 80	Segmentação direto na imagem original
80 < Média < 100	Filtro Butterworth
Média > 100	Filtro Butterworth

Fonte: autoria própria.

Além da utilização das médias como parâmetro para definição da estratégia, também foi necessário considerar o corte anatômico e algumas particularidades de cada corte. Uma vez que a base de dados apresenta imagens com regiões cranianas mais espessas que outras, Figura 11, o pré-processamento teve que ser subdividido em etapas de morfologia matemática para remoção destas regiões. Após o teste com as 100 (cem) imagens, foi observado que para todos os tipos de corte a segmentação apresentava dificuldades quando se tratava de regiões com maior espessura da caixa craniana, característica essa que não poderia ser contornada apenas com a primeira etapa de remoção (Figura 11(b) e 11(e)). Portanto, nesse caso as imagens foram submetidas a uma segunda morfologia matemática com a operação de erosão e elemento estruturante variando conforme a faixa de intensidade que a imagem se encontrava, com o objetivo de evitar a detecção de falsos objetos de interesse.

Durante a análise do conjunto de dados de teste alguns padrões foram observados: imagens que apresentavam média de intensidade entre 80 e 100 (Figura 11(a)), foram submetidas a uma segunda morfologia matemática com a operação de erosão e elemento estruturante de disco com raio igual a 7 (Figura 11(c)). Enquanto *slices* com média maior que 100 (Figura 11(d)), representavam caixas cranianas muito espessas, o que explica as médias de intensidades mais próximas de 255 ou branco. Nestes casos, os exames tiveram que passar por um segundo processo morfológico com elemento estruturante ainda maior que o anterior, de raio igual a 15 (Figura 11(f)). Tais procedimentos, auxiliam no desempenho do processo de segmentação visto que eliminaram as informações indesejadas da região do crânio e que interferiam diretamente na etapa seguinte.

Figura 11: (a) imagem original com média de intensidade entre 80 e 100; (b) primeira remoção craniana referente à imagem “a”; (c) segunda remoção craniana referente à imagem “a”; (d) imagem original com média de intensidade maior que 100; (e) primeira remoção craniana referente à imagem “d”; (f) segunda remoção craniana referente à imagem “d”.

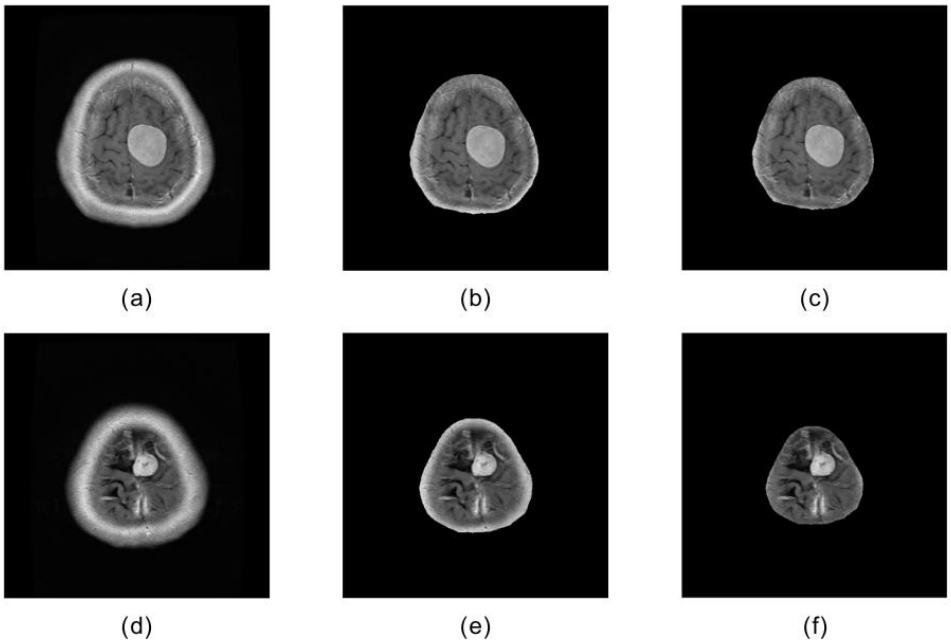

Fonte: autoria própria.

Quando tratamos dos cortes coronais e sagitais, além da caixa craniana, existem outros dados que geram interferência na segmentação: às regiões do pescoço, nariz e olhos. Nesse caso, realizamos um corte na região inferior do *slice* com uma altura média (Figura 12) e em seguida a região recortada foi preenchida com *pixels* pretos iguais ao *background*, Figura 12(b), o que manteve a imagem com o tamanho original, ou seja, não prejudicou as demais operações aplicadas sobre a imagem.

Figura 12: (a) imagem original de um corte coronal e (b) resultado do corte da região inferior.

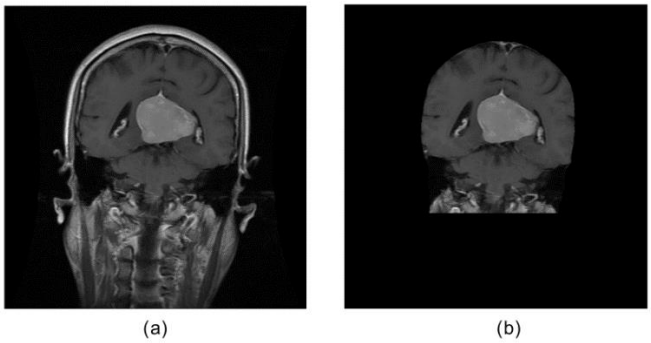

Fonte: adaptado da base de dados.

4.3.2. SEGMENTAÇÃO

O processo de segmentação foi considerado como o mais importante de todo algoritmo, visto que delimita a região de interesse a partir da imagem pré-processada. Para este trabalho foi adotado a técnica de agrupamento *k-means*, utilizada com o objetivo de organizar os *pixels* em grupos conforme semelhanças encontradas em suas características. Para os exames que apresentavam média de intensidade com valores entre 63 e 80, a segmentação por *k-means* foi aplicada na imagem apenas com a primeira morfologia matemática de retirada craniana, e apresentou resultados importantes com o valor de 5 centros. Contudo, nas demais situações a segmentação aconteceu na imagem pré-processada após aplicação dos filtros passa alta e com *cluster* de valor igual a 4. Outra característica marcante observada para esta técnica, quando aplicada nas imagens da base de dados, foi que entre as classes segmentadas após aplicação do algoritmo de *k-means*, a classe correspondente ao tumor era sempre a que possuía centroide de valor máximo, o que nos possibilitou sempre obter como saída do sistema a máscara equivalente a região do tumor, Figura 13.

Figura 13: (a) Imagem original; Segmentação *K-means*: (b) Classe 1 - Centroide = 132.8939; (c) Classe 2 - Centroide = 0.0890; (d) Classe 3 - Centroide = 53.7483; (e) Classe 4 - Centroide = 41.9858.

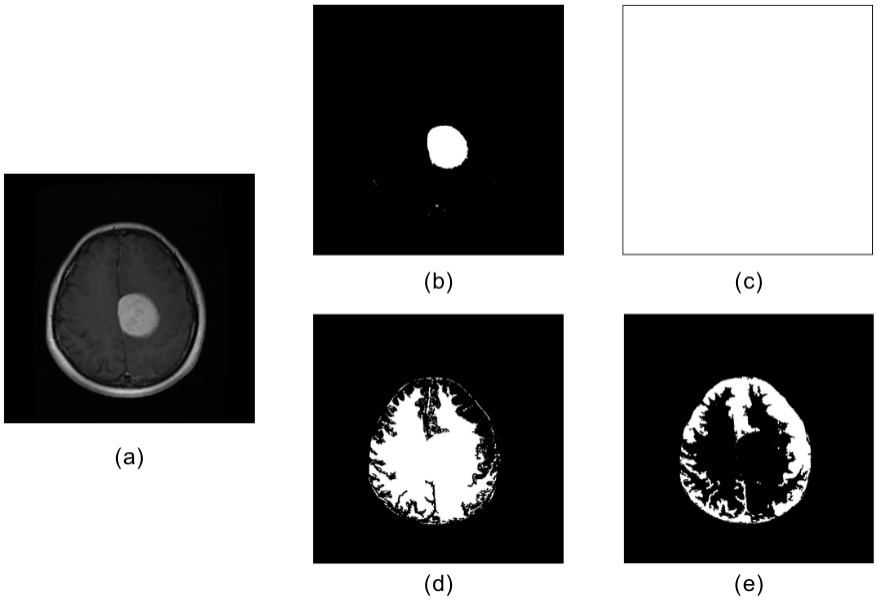

Fonte: autoria própria.

4.3.3. PÓS-PROCESSAMENTO

Com o processo de segmentação foi obtido como saída uma máscara da região tumoral, porém as imagens apresentavam pequenas descontinuidades nas bordas e buracos provenientes da etapa de segmentação, sendo necessário corrigi-las sem que provocasse grandes alterações no resultado. Dessa forma, foi aplicado morfologia matemática através da operação de fechamento para amenizar essas descontinuidades, processo este representado na Figura 14 e conhecido como etapa de pós-processamento.

Figura 14: (a) Imagem original e (b) Pós-processamento com técnica de morfologia matemática.

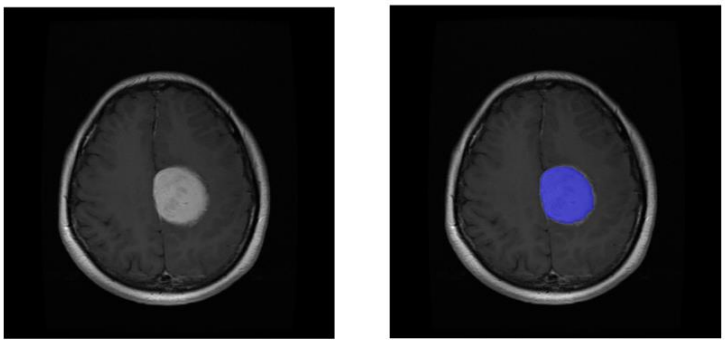

Fonte: autoria própria.

Após análise do total de 100 (cem) imagens e identificação dos padrões de ocorrência, foi definida a estratégia geral baseada na média das intensidades e corte anatômico relativo a cada exame, como descrito na Figura 15, sendo este modelo aplicado nas demais imagens testadas.

Figura 15: Diagrama de blocos da estratégia geral adotada para segmentação dos tumores do tipo meningioma conforme a média de intensidades e corte anatômico.

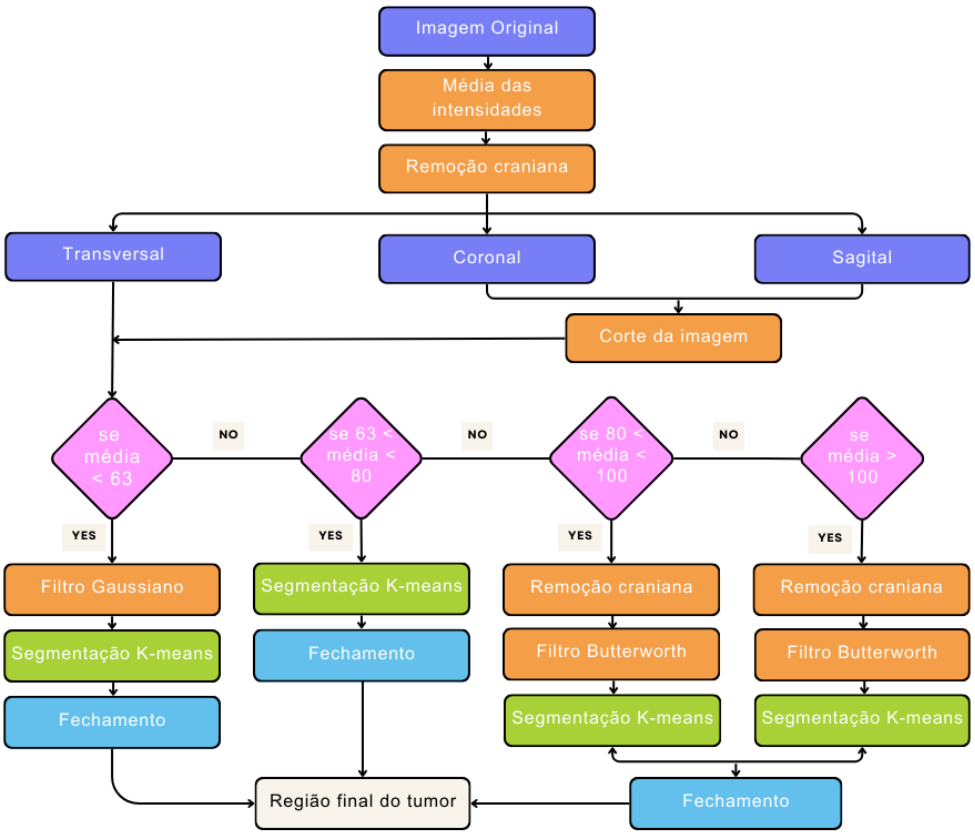

Fonte: autoria própria.

Com o objetivo de validar os resultados encontrados, foi abordado duas características importantes: a avaliação visual de semelhança e o cálculo da porcentagem de acerto em relação a imagem segmentada pelos especialistas. A porcentagem de acerto foi calculada analisando cada *pixel* da máscara fornecida na base de dados e sua correspondência com os *pixels* da imagem de saída do sistema. Uma vez que os *pixels* brancos da máscara dos especialistas correspondiam a 100%, por meio de uma regra de três simples e a quantidade de *pixels* brancos da imagem segmentada que estavam corretamente agrupados, foi obtido o valor da porcentagem de acerto. Por outro lado, a avaliação da semelhança entre a região de interesse e o resultado encontrado com a segmentação do sistema, ocorreu através da sobreposição da região do tumor com a imagem original e uma análise visual. Assim, o resultado seria considerado positivo caso ambas as condições fossem aceitas. Vale ressaltar que todo o processo descrito na estratégia foi realizado de forma semiautomática, em que o usuário apenas seleciona a imagem e o corte anatômico correspondente, e o algoritmo realiza todo o processo sem interferências.

Com o crescimento exponencial dos sistemas de informação e tecnologias cada vez mais robustas, a ideia de *interface* do usuário (UI) se apresenta como um elemento importante para qualquer produto ou serviço. Silveira (2023) descreve que "a *interface* do usuário serve como uma ponte entre a pessoa usuária e o produto, proporcionando uma experiência de uso que seja intuitiva, eficiente e agradável". Levando em consideração o conceito de UI apresentado, o sistema foi desenvolvido com o auxílio do *guide* no MATLAB, com o objetivo de obter uma *interface* mais intuitiva e proporcionar uma melhor usabilidade ao usuário final, como apresentado na Figura 16.

No painel lateral esquerdo existem três passos para executar as tarefas dentro do sistema: ler imagem (Figura 16(a)), permite que seja escolhido um exame de imagem dentro da base de dados; definição do corte anatômico (Figura 16(b)), uma vez que a base de dados disponibiliza IRM em três tipos de corte foi necessário definir estratégias distintas para cada *slice* conforme a disposição anatômica, levando em consideração o comportamento individual de cada corte; e processamento (Figura 16(c)), função que corresponde à fase de segmentação da região tumoral e extração das características.

Figura 16: Tela principal do sistema desenvolvido. (a) botão de pesquisa da imagem original, (b) definição do tipo de corte anatômico, (c) etapa de segmentação do tumor.

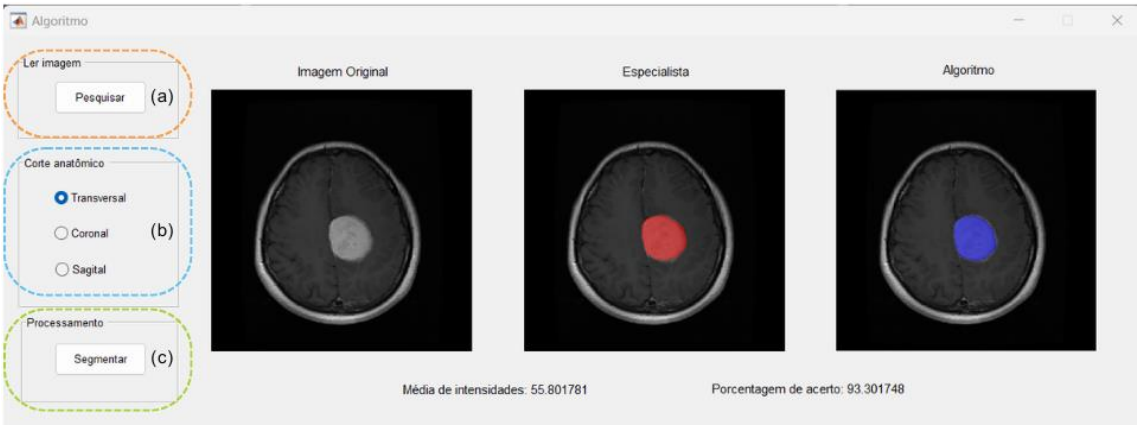

Fonte: autoria própria.

Após implementação dos itens do menu lateral, os resultados serão dispostos nas caixas ao lado. Na primeira posição está a imagem original (Figura 17(a)), referente a execução do botão pesquisar. Em seguida, a máscara segmentada pelo especialista e disponível na base de dados (Figura 17(b)), que foi sobreposta na imagem original para fins de comparação visual. Na última região de exibição, o resultado da segmentação do sistema implementado neste trabalho (Figura 17(c)), com a sobreposição no exame

original a fim de comparação com a máscara de forma visual e percentual. O algoritmo também demonstra na parte inferior da tela principal o valor da média das intensidades dos *pixels* e os índices da porcentagem de acerto entre as duas imagens do tumor segmentado (Figura 17(d)).

Figura 17: Tela principal do sistema desenvolvido. (a) exibição da imagem original, (b) máscara de segmentação do especialista, (c) imagem após segmentação do sistema desenvolvido, (d) média das intensidades dos *pixels* e porcentagem de acerto.

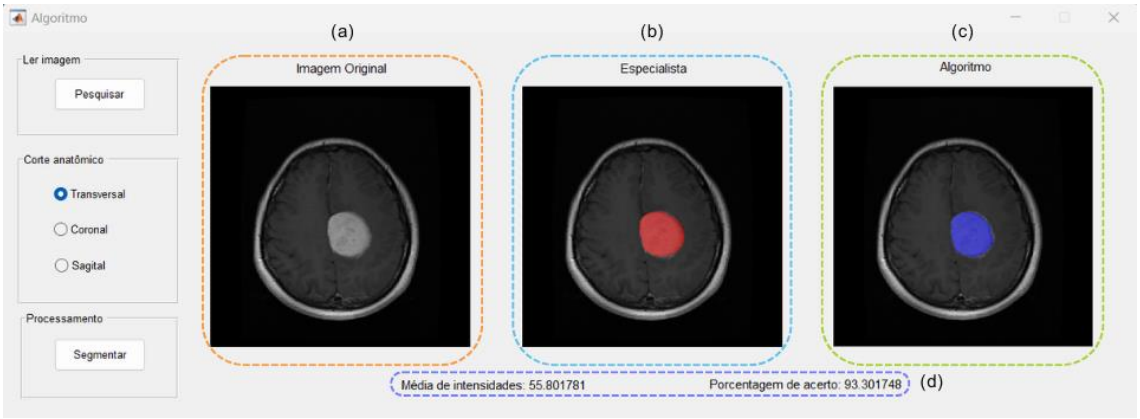

Fonte: autoria própria.

5. RESULTADOS E DISCUSSÕES

A estratégia algorítmica proposta no presente trabalho foi aplicada apenas nas imagens correspondentes ao tumor do tipo meningioma presente na base de dados, portanto, foram testadas um total de 705 imagens. Dentro do grupo de imagens correspondentes a meningiomas existe uma subdivisão por categoria de corte anatômico, sendo 207 *slices* referentes ao corte transversal, 231 com corte coronal e 267 ao corte sagital. A análise dos resultados foi realizada de forma separada abrangendo o conjunto de imagens de cada um dos subgrupos, a fim de comparar a aplicação do algoritmo sobre cada tipo de corte.

Para fins de interpretação, na verificação geral foi avaliado quantas vezes o algoritmo acertou a região de interesse, independente de realizar os contornos completamente corretos. Para isso, consideramos a região correta quando o algoritmo destacava a região correspondente à máscara fornecida pelo especialista, independente da porcentagem de acerto. Consequentemente, a região errada foi associada a locais diferentes de evidência quando comparados com a delimitação da base de dados.

Além disso, foi traçada uma segunda perspectiva com uma análise mais profunda, onde além de destacar a região correta foi analisada a porcentagem de correspondência entre a imagem segmentada pelo algoritmo e a máscara presente na base de dados, que deveria constar um índice acima de 70% para ser considerado como resultado aceitável. Quando relatamos que o resultado encontrado foi parcial, nesse caso a região encontrada estava correta, porém os limites da região de interesse foram ultrapassados.

5.1. CORTE TRANSVERSAL

Após realizado o teste em todas as imagens do corte transversal foi observado que em 169 casos o algoritmo destacou a região de interesse corretamente, conforme a região demarcada na base de dados. E destacamos que em 112 exames esse acerto foi obtido com precisão maior que 70% de correspondência com os limites demarcados na máscara dos especialistas. Dessa forma, apenas 38 imagens não foram demarcadas na localização correta (Tabela 4).

Tabela 4: Resultados gerais e específicos para o corte transversal em tumores do tipo meningioma.

***Status* da análise**	**Quantidade**	**Porcentagem**
Região Correta	**169**	**81,64%**
Acerto > 70%	112	54,11%
Acerto < 70%	47	22,71%
Parcial	10	4,83%
Região Errada	**38**	**18,36%**
Total	**207**	**100%**

Fonte: autoria própria.

5.2. CORTE CORONAL

Para as imagens do corte coronal, de um total de 231 *slices* foi analisado que a região de interesse estava destacada corretamente em 191 casos, apresentando erros na posição do tumor em apenas 40 situações. Além disso, a porcentagem de acerto apresentou índice de correspondência maior que 70% em 127 exames (Tabela 5).

Tabela 5: Resultados gerais e específicos para o corte coronal em tumores do tipo meningioma.

***Status* da análise**	**Quantidade**	**Porcentagem**
Região Correta	**191**	**82,68%**
Acerto > 70%	127	54,98%
Acerto < 70%	57	24,68%
Parcial	7	3,03%
Região Errada	**40**	**17,32%**
Total	**231**	**100%**

Fonte: autoria própria.

5.3. CORTE SAGITAL

O corte sagital era o que apresentava maior quantidade de imagens, um total de 267 IRM. Após o teste de toda a base de dados referente a esse tipo de corte com tumor meningioma, foi detectado que obtivemos a região correta em 155 imagens. Entretanto, o algoritmo não apresentou sucesso na identificação da área de interesse em 112 casos. Por outro lado, 97 imagens entre aquelas que estavam dentro da região correta alcançaram índices de correspondências maiores do que o esperado (Tabela 6).

Tabela 6: Resultados gerais e específicos para o corte sagital em tumores do tipo meningioma.

***Status* da análise**	**Quantidade**	**Porcentagem**
Região Correta	**155**	**58,05%**
Acerto > 70%	97	36,33%
Acerto < 70%	48	17,98%
Parcial	10	3,75%
Região Errada	**112**	**41,95%**
Total	**267**	**100%**

Fonte: autoria própria.

5.4. DISCUSSÕES

Depois de aplicar a estratégia algorítmica em todas as imagens de meningiomas e em todos os tipos de corte, foi verificado que a quantidade de vezes que o programa acertou a região de interesse nos cortes transversal e coronal corresponde a um valor maior que 80% nas duas situações. E em relação a comparação com a máscara do especialista, avaliando uma porcentagem de correspondência maior que 70%, os resultados alcançados foram corretos em cerca de aproximadamente 54% das imagens para os dois tipos de corte, o que indica resultados importantes para o trabalho, uma vez que foram atingidas segmentações próximas das máscaras dos especialistas em mais da metade dos dados analisados.

Além disso, foram obtidos resultados de semelhança, superiores a 90%, com a máscara em 36 imagens relativas ao corte transversal, 18 exames do corte coronal e 25 imagens do corte sagital. Assim, foi alcançado um valor máximo de compatibilidade de 96,45% referente a uma imagem do corte sagital (Figura 18). Dessa forma, foi inferido que os resultados obtidos com o corte transversal de uma forma geral são mais efetivos em relação aos demais. Entretanto, mesmo com uma porcentagem menor de acertos, o corte sagital apresentou uma quantidade superior de correspondência maior que 90% quando comparado ao corte coronal.

Figura 18: Resultado máximo de compatibilidade alcançado com a aplicação do algoritmo.

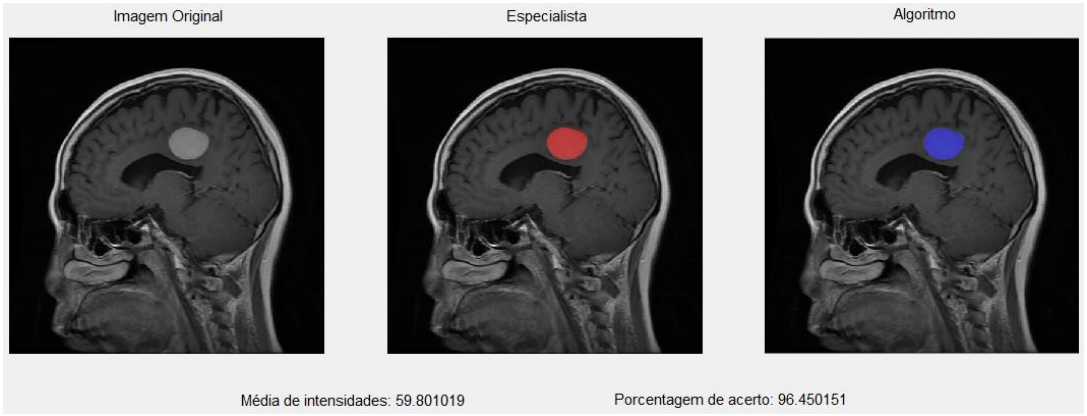

Fonte: autoria própria.

Outro ponto de destaque para os resultados alcançados diz respeito à quantidade de imagens que resultaram na segmentação correta mesmo apresentando uma grande quantidade de características que em outras situações dentro da mesma base de dados atrapalharam o processo, como por exemplo, a região dos olhos, nariz, boca e pescoço. No caso da Figura 19, temos uma imagem com corte transversal e presença de artefatos relacionados ao olho e região craniana, contudo, foi percebido que o algoritmo contornou de forma apropriada, gerando um resultado adequado com compatibilidade de 93,57%.

Figura 19: Resultado para um corte transversal com presença de artefatos relacionados a olhos e região craniana.

Fonte: autoria própria.

A seguir temos outros exemplos da presença de artefatos em imagens dos pacientes e que foram gerados resultados importantes. No primeiro caso foi usado uma

imagem de corte coronal em que o resultado foi de aproximadamente 89,53%, Figura 20(a), mesmo com a presença de região craniana, ossos e músculos da face. De maneira semelhante, para o corte sagital foi alcançado um índice de 85,2% de acerto, apesar das interferências associadas à região do pescoço, maxilar e caixa craniana, Figura 20(b)

Figura 20: (a) Resultado para um corte coronal com a presença de artefatos relacionados à região craniana, ossos e músculos da face; e (b) Resultado para um corte sagital com a presença de artefatos relacionados à caixa craniana, pescoço e região do maxilar.

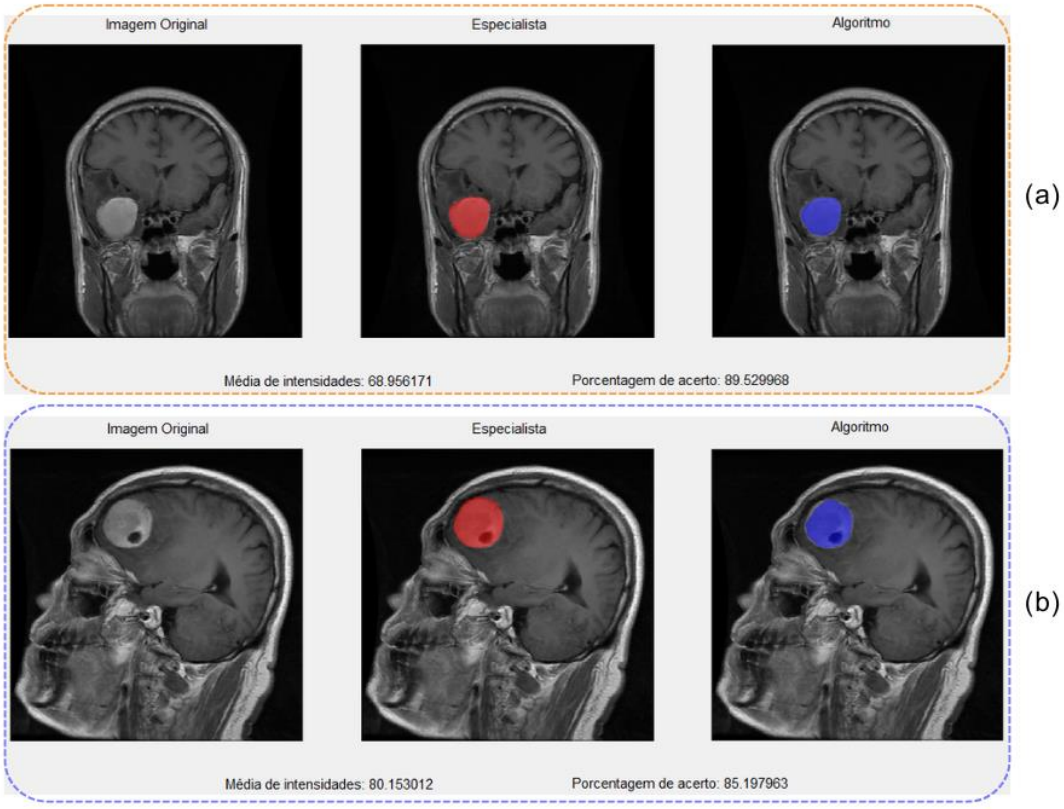

Fonte: autoria própria.

Apesar de todos os resultados importantes obtidos ao longo dos testes, os artefatos mencionados anteriormente também tiveram influências negativas nas respostas geradas. Uma grande parte das situações relacionadas aos casos errados está vinculada aos artefatos que não conseguiram ser contornados pelo algoritmo, dentre eles o mais comum foram os olhos, principalmente nos cortes transversal e coronal, onde esta região estava mais evidente (Figura 21).

Figura 21: (a) Resultado incorreto para um corte transversal; e (b) resultado incorreto para um corte coronal.

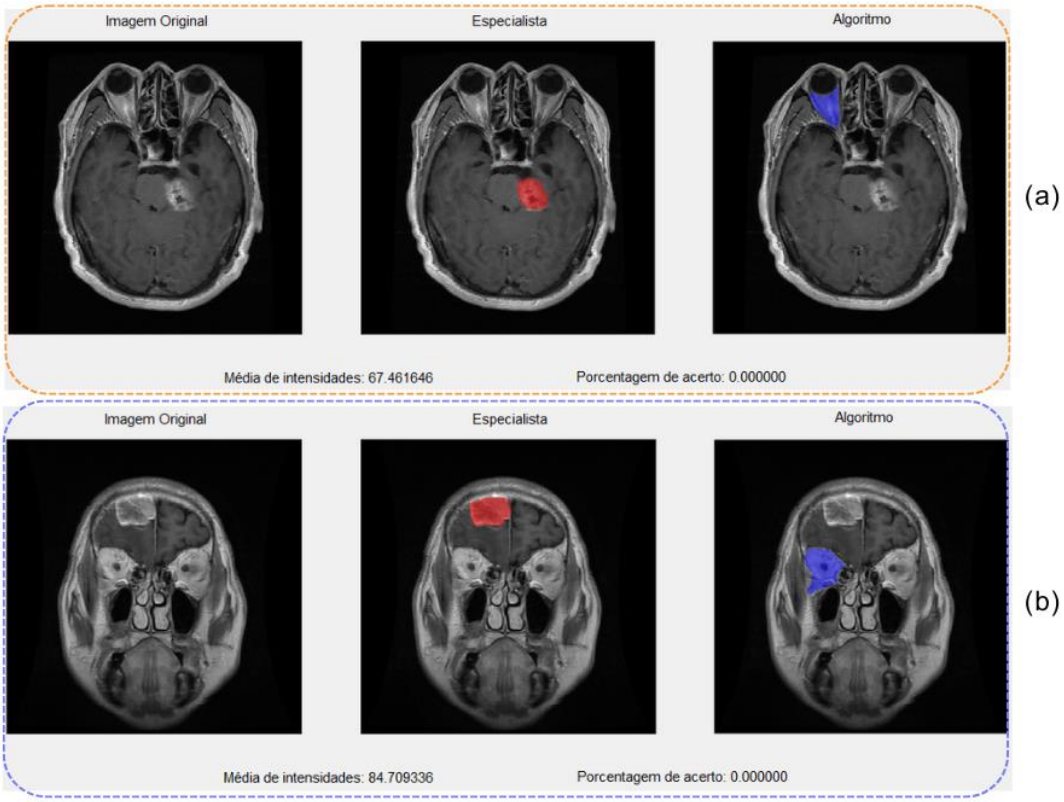

Fonte: autoria própria.

Quando comparado os resultados com os índices alcançados no projeto inicial (Apêndice A), foi observado um aumento de aproximadamente 20% de acerto na região de interesse.

Dessa forma, foi observado que as técnicas aplicadas junto à estratégia conseguiram contornar as situações adversas para a maioria dos casos, onde foi atingido uma quantidade apropriada de acertos em relação à localidade do tumor, em que mais de 80% dos casos apontaram corretamente para a região patológica. E desses resultados corretos mais da metade apresentando uma porcentagem de correspondência elevada, acima dos 70%, quando comparadas com as máscaras segmentadas por especialistas da área.

6. CONCLUSÕES

A análise de imagens médicas, uma tarefa complexa e que exige conhecimentos profundos da parte do especialista, a fim de evitar falsos diagnósticos ou delimitações erradas em torno da patologia. Portanto, trata de um serviço ainda mais árduo por se referir a saúde e vida de pessoas, o que exige um nível de atenção e cuidados elevados. Dessa forma, o programa proposto neste trabalho tem uma função importante no auxílio dessa avaliação por parte da equipe médica especializada, com perspectivas de ajudar na delimitação dos tumores e assim proporcionar o melhor tratamento possível.

Os resultados obtidos mostram que o algoritmo obteve um desempenho importante, porém de forma alguma exclui a necessidade de avaliação e acompanhamento de um profissional da área. Contudo, atuando de forma conjunta o esperado é que os resultados sejam ainda mais efetivos. Além disso, o sistema desenvolvido tem uma adaptação para o usuário, funcionando de forma semiautomática, o que proporciona uma melhor usabilidade com experiência de uso intuitiva e eficiente.

O trabalho foi desenvolvido utilizando as ferramentas básicas de manipulação de imagens digitais, e os resultados alcançados demonstraram que foi possível chegar a respostas com um alto nível de compatibilidade se comparado a outras técnicas mais robustas.

Com o avanço das tecnologias de imagem e das técnicas computacionais disponíveis para manipulação desses exames, a perspectiva traz que resultados ainda mais expressivos sejam atingidos ao longo do tempo.

6.1. TRABALHOS FUTUROS

A partir do trabalho elaborado, são sugeridos alguns pontos que podem ser desenvolvidos e serem aplicados como trabalhos futuros: extração de características como área e volume da região de interesse, desenvolvimento de uma visualização 3D do tumor, aplicação de métodos de aprendizado profundo e validação do sistema desenvolvido com especialistas da área.

6.2. CONTRIBUIÇÕES DO TRABALHO

A partir da discussão dos resultados obtidos com o algoritmo e das análises realizadas, foi possível afirmar que as máscaras alcançadas com o método implementado neste trabalho podem auxiliar os especialistas na delimitação das regiões tumorais. O programa desenvolvido conseguiu atingir os objetivos delimitados, neste caso, gerar uma máscara baseada na segmentação da região referente ao tumor do tipo meningioma. Portanto, permitindo que o profissional tenha o auxílio da tecnologia para ajudar na tarefa difícil como analisar imagens com muitas regiões em níveis de cinza e que podem trazer confusões para profissionais com pouca experiência.

Com a utilização da ferramenta desenvolvida por meio das técnicas básicas de Processamento Digital de Imagens, o especialista além de contar com uma ajuda na visualização dos exames, pode dispor de um método que colabora para diagnósticos precoces e acompanhamento de pós-operatórios. Portanto, auxiliando também no tratamento e maiores chances de recuperação dos pacientes. Além disso, se trata de uma tecnologia capaz de oferecer para sociedade um auxílio computadorizado no diagnóstico e com baixo custo de implementação.

Ademais o projeto inicial contou com algumas das técnicas básicas implementadas e aprimoradas neste trabalho, sendo apresentado no CLAIB&CBEB 2022: IX Congresso Latino-Americano de Engenharia Biomédica e XXVIII Congresso Brasileiro de Engenharia Biomédica, que aconteceu em Florianópolis – SC em outubro de 2022. O projeto inicial contou também com sua publicação pela *International Federation for Medical and Biological Engineering – IFMBE Proceedings Book,* volume 99 (Apêndice A).

7. REFERÊNCIAS BIBLIOGRÁFICAS

ARAGÃO, M. F. V. V.; VALENÇA, M. M. *A ressonância magnética em tumores astrocitários: avaliação da associação de padrão existente com a graduação histopatológica.* Tese de Doutorado - Programa de Pós-Graduação em Neuropsiquiatria e Ciência do Comportamento, Universidade Federal de Pernambuco, Recife, 2010.

CHENG, J.; HUANG, W.; CAO, S.; YANG, R.; YANG, W.; YUN, Z.; WANG, Z.; FENG, Q. (2015) *Enhanced Performance of Brain Tumor Classification via Tumor Region Augmentation and Partition.* PLoS ONE 10(10): e0140381. doi:10.1371/journal.pone.0140381.

CONTRERAS, L. E. *Epidemiología de tumores cerebrales*. Revista Médica Clínica Las Condes. Vol. 28. Issue 3. Pages 332-338, 2017.

FRANCE PRESSE. *Aparelho de ressonância mais potente do mundo revela imagens inéditas do cérebro humano*. G1, 2024. Disponível em: <https://g1.globo.com/saude/noticia/2024/04/02/aparelho-de-ressonancia-mais-potente-do-mundo-revela-imagens-ineditas-do-cerebro-humano.ghtml>. Acesso em: 04 de junho de 2024.

GONZALES, R. C.; WOODS, R. C. Processamento digital de imagens. 3. Ed. São Paulo: Pearson Prentice Hall, 2010.

GROVER, V.P.; TOGNARELLI, J.M.; CROSSEY, M.M.; COX, I.J.; TAYLOR-ROBINSON, S.D.; MCPHAIL, M.J. *Imagem por Ressonância Magnética: Princípios e Técnicas: Lições para Clínicos*. Journal Clinical Experimental Hepatology. Setembro de 2015. DOI: 10.1016/j.jceh.2015.08.001.

INCA – Instituto Nacional de Câncer, 2020. *Câncer do Sistema Nervoso Central*. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/cancer/tipos/sistema-nervoso-central>. Acesso em: 24 de setembro de 2022.

MENDES JÚNIOR, D. E. *Utilização do algoritmo k-means na segmentação e classificação de imagens de refeições*. Monografia (Bacharelado em Ciências da Computação) - Universidade Federal de Alfenas. Alfenas, p. 75. 2015.

LAUKAMP, K.R.; THIELE, F.; SHAKIRIN, G.; ZOPFS, D.; FAYMONVILLE, A.; TIMMER, M.; MAINTZ, D.; PERKUHN, M.; BORGGREFE, J. *Fully automated detection and segmentation of meningiomas using deep learning on routine multiparametric MRI.* European Radiology. 2019 Jan; 29(1):124-132. doi: 10.1007/s00330-018-5595-8.

LOUIS, D. N.; OHGAKI, H.; WIESTLER, O. D.; CAVENEE, W. K.; BURGER, P. C.; JOUVET, A.; SCHEITHAUER B. W.; KLEIHUES, P. *WHO Classification of Tumors of the Central Nervous System*. WHO Regional Office Europe, 2007.

MACHADO, A. B. M. *Neuroanatomia Funcional*. 3 ed. São Paulo: Atheneu, 2014.

MADUREIRA, L. C. A.; OLIVEIRA, C. S.; SEIXAS, C.; NARDI, V. D.; ARAÚJO, R. P. C.; ALVES, C. (2010). *Importância da imagem por ressonância magnética nos estudos dos processos interativos dos órgãos e sistemas*. Revista De Ciências Médicas E Biológicas, 9(1), 13–19. https://doi.org/10.9771/cmbio.v9i1.4727.

MAROSI, C.; HASSLER, M.; ROESSLER, K.; RENI, M.; SANT, M.; MAZZA, E.; VECHT, C. *Meningioma*. Critical Reviews in Oncology/Hematology 67, 2008. doi:10.1016/j.critrevonc.2008.01.010.

MARQUES, O. F.; VIEIRA, H. N. *Processamento Digital de Imagens*, Rio de Janeiro: Brasport, 1999. ISBN 8574520098.

MARTINEZ, Ana. *Neuroanatomia Essencial* / Ana Martinez, Silvana Allodi, Daniela Uziel. – 1. Ed. – Rio de Janeiro: Guanabara Koogan, 2014.

MASCARENHAS, L.R.; RIBEIRO, J. A. S.; RAMOS, R. P. *Automatic segmentation of brain tumors in magnetic resonance imaging. einstein* (São Paulo). 2020;18:eAO4948. http://dx.doi.org/10.31744/einstein_journal/2020AO4948.

MathWorks. *Matrix Laboratory*. Disponível em: <https://www.mathworks.com/products/matlab.html>. Acesso em: 17 de novembro de 2022.

MathWorks. *Matrix Laboratory*. Disponível em: <https://www.mathworks.com/help/images/ref/strel.html>. Acesso em: 12 de agosto de 2024.

MAZZOLA, Alessandro A. *Ressonância magnética: princípios de formação da imagem e aplicações em imagem funcional*. Artigo de revisão. Revista Brasileira de Física Médica, 2009; 3(1):117-29.

MENDES, G. A.; ONGARATTI, B. R.; PEREIRA-LIMA, J. F. S. *Epidemiologia de uma série de tumores primários do sistema nervoso central*. Universidade Federal de Ciências da Saúde de Porto Alegre (UFCSPA), Porto Alegre, RS, Brasil. Arquivos Brasileiros de Neurocirurgia 33(4): 279-83, 2014.

OSTROM, Q. T.; PATIL, N.; CIOFFI, G.; WAITE, K.; KRUCHKO, C.; BARNHOLTZ-SLOAN, J. S. *CBTRUS statistical report: primary brain and other central nervous system tumors diagnosed in the United States in 2013-2017*. Society for Neuro-Oncology. 22(S1), 1-96, 2020.

QUEIROZ, J. E. R.; GOMES, H. M. *Introdução ao processamento digital de imagens*. Revista RITA: instruções para preparação de documentos em Word. RITA – Vol. VIII – Número 1, 2001.

RASOOL, M.; ISMAIL, N.A.; BOULILA, W.; AMMAR, A.; SAMMA, H.; YAFOOZ, W.M.S.; EMARA, A.H.M. *A Hybrid Deep Learning Model for Brain Tumour Classification*. Entropy 2022, *24*, 799. https://doi.org/10.3390/e24060799.

SHAIKH, M. D. S.; CHOUDHRY, A. e WADHWANI, R. *Analysis of Digital Image Filters in Frequency Domain.* International Journal of Computer Applications (0975-8887). Volume 140 - n° 6, April 2016.

SILVEIRA, Maria Isabelle. *UI Design: o que é, UX vs UI e um guia da profissão de UI Designer*. Alura, 2023. Disponível em: <https://www.alura.com.br/artigos/ui-design#:~:text=A%20interface%20do%20usu%C3%A1rio%20serve,seja%20intuitiva%2C%20eficiente%20e%20agrad%C3%A1vel>. Acesso em: 07 de agosto de 2024.

SONI, Akanksha e RAI, Avinash. *CT Scan Based Brain Tumor Recognition and Extraction using Prewitt and Morphological Dilation*. International Conference on Computer Communication and Informatics (ICCCI - 2021), Coimbatore, India.

VIANA, A. S.; SANTOS, C. S. C., JÚNIOR, R. O. S.; MENDES, A. C. *Processamento e Análise Digital de Imagem (PADI): quantificação grão/não-grão e estimativa de porosidade a partir de imagens em laminas delgadas*. Sociedade Brasileira de Geofísica, SBGf, 2017.

ZULKOFFLI, Z.; SHARIFF, T. A. *Detection of brain tumor and extraction of features in MRI images using k-means clustering and morphological operations.* 2019 IEEE International Conference on Automatic Control and Intelligent Systems (I2CACIS 2019), 29 June 2019, Selangor, Malaysia.

APÊNDICE A

Application of digital image processing techniques for segmentation of meningiomas in magnetic resonance images

Beatriz Vasconcelos de Oliveira[1[0009-0001-1811-0967]], William Marcos Dantas[1[0009-0007-8909-788X]], Caroline Dantas Vilar[1[0009-0007-8717-8969]] and Heliana Bezerra Soares[1[0000-0002- 0833-7906]]

[1] Federal University of Rio Grande do Norte / Biomedical Engineering Department, Natal – RN, Brazil

[1] Corresponding Author: beatriz.vasconcelos.106@ufrn.edu.br

Abstract. Brain tumor is of the main diseases that affect the brain, meningioma being the most common among all types of brain tumors. This pathology has a benign character in most situations. In order to aid in a rapid and non-invasive prognosis, magnetic resonance imaging is used as the means of diagnosis. Therefore, with the objective of developing a tool to assist in the analysis of the lesion and medical decisions, an algorithmic strategy of automatic segmentation was developed for magnetic resonance images of meningiomas, in order to delimit the tumor region from the application of processing techniques digital images. The results obtained in this analysis corresponded to about 66% of correct answers in the segmentation of the region of interest.

Keywords: Brain tumor, meningioma, digital image processing.

1 Introduction

Brain tumor is a disease that affects the nervous system and can be classified into two types: primary and secondary. Primary brain tumors are those that originate in the central nervous system itself, while secondary tumors originate from another region of the body and reach the brain through metastases [1].

Among the most frequent primary brain tumors is the meningioma, characterized by its common location in the meninges region and classified as a benign type of tu- mor for most cases, it also presents slow growth, with exposure to ionizing radiation as one of the main risk factors [1].

The World Health Organization has specified a classification that encompasses four grades of lesions to determine the severity of each tumor, subdivided into two categories: low grade (types I and II) and high grade (types III and IV). In relation to meningiomas, this classification is characterized by only three levels: grade I – lesions with low infiltration potential, considered typical; grade II – lesions with high infiltration potential, called atypical; grade III – less common type, but with anaplastic or malignant characteristics [2].

The diagnostic process of this pathology includes the analysis of neuroimages as a crucial step, the most common exams being: computed tomography and magnetic resonance imaging.

Magnetic resonance imaging is an image acquisition process based on nuclear spins and their interactions with the magnetic field generated by the equipment. These interactions are more intense in the hydrogen atom, since its nucleus has only one proton, so it presents angular momentum when subjected to the magnetic field. Therefore, as there is a diversity in the amount of hydrogen present in the tissues, for each sequence of electromagnetic pulses the tissues will present a different recovery time, which translated into the final image, represents a different intensity for each type of

tissue [3].

Although this type of image is excellent for identifying the existence of the tumor and delimiting its region, there are some points that cannot be met by this modality, such as: definition of the type, degree of malignancy and approximation of the impregnation margins. However, the limitations mentioned above can already be overcome from the association of magnetic resonance images with more recent techniques [4].

The evaluation of imaging tests to identify tumor regions still takes place manually by specialist physicians, which requires a great deal of professional experience and a well-trained eye to identify these pathologies. This specificity can influence the final segmentation area, since this procedure is subject to natural human errors and is difficult to visualize, due to the nature of the image that has many similar levels of intensity [5]. Therefore, the computer-aided diagnosis system – CAD shows itself as an important alternative to aid in the detection and segmentation of brain tumors. In addition to contributing to an early diagnosis, which is a crucial factor in the efficiency of the treatment response and consequently in the patient's chances of recovery.

According to data from Brazilian National Cancer Institute – INCA (2022), among the total percentage of malignant tumors, cancer of the central nervous system corresponds to 1.8%. In addition, as estimate carried out in the year 2020 points to the emergence of 11.090 new cases, with a mortality rate that can reach the amount of 9.355 of the total cases [6].

Based on this problem and the data presented in the previous paragraph, the objective of this work is to develop a computational algorithm that, applied to magnetic resonance images, is able to identify and segment the region referring to meningioma-type brain tumors, through the application of digital image processing techniques.

2 Materials and methods

2.1 Database

The database was produced and made available by Nanfang General Hospital and Tianjing Medical University General Hospital, both in China, and is publicly available for research use. The data are composed of T1-weighted MRI images of the brain region and have three distinct types of brain tumors: meningiomas, gliomas and pituitary tumors. The dataset refers to 233 patients, totaling 3.064 slices, of which 708 are meningiomas [7].

In a very generic way, we can explain that during an MRI exam, the images are generated through a kind of scan, that is, at the end of the analysis there are several slices of the region of interest of a patient, better known as slices. Therefore, the same individual may contain more than one image referring to their lesion.

In this database, the information of each slice is distributed within a struct with the extension .mat, and includes the identification of the tumor type, the patient's identity code, the original image (see Fig. 1), a vector of coordinates and a tumor mask [7].

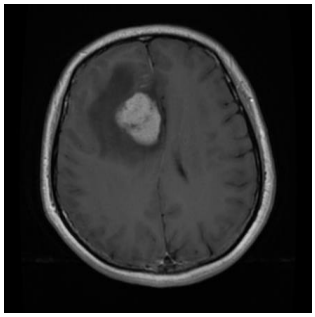

Fig. 1 Original image extracted from .mat file.

In addition to the original images of each patient, the author has a binary mask of

the tumor region (see Fig. 2), which was segmented by three experienced professionals in the neurological area. From the analysis of these images in comparison to the originals, we noticed a discrepancy in the information, since the manual segmentation brought a visually larger region than the original. Therefore, for the purpose of evaluating the results, this study did not use these images as a parameter for comparison.

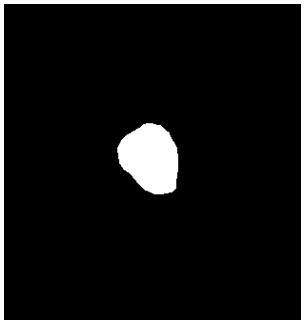

Fig. 2 Specialist segmented tumor mask, extracted from .mat file.

2.2 Digital image processing

For the development of the algorithm we used a sequence of digital image processing strategies, as described in Fig. 3, with the objective of segmenting the characteristic region of the tumor from the magnetic resonance image.

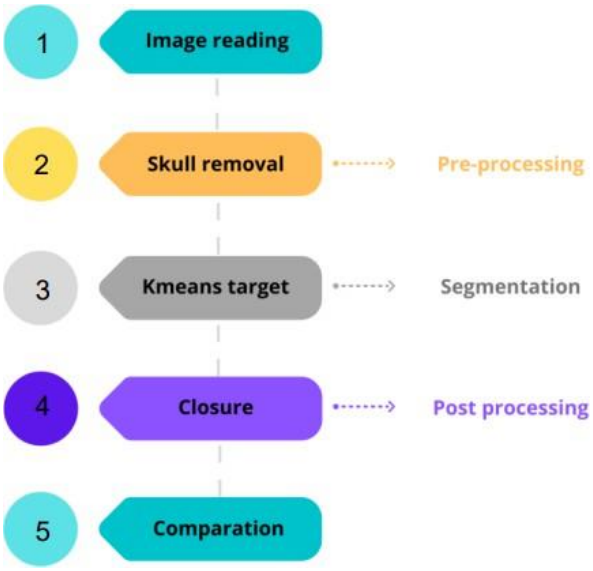

Fig. 3 Block diagram with the techniques applied in the system.

Executing the first step of the algorithm, reading the image, it was necessary to extract the original image that was inside a struct and consequent conversion of this figure to the .png format. In this way, we were able to work in the other stages with the original image.

We have divided the processes into three main phases: pre-processing, segmentation and post-processing. In the pre-processing, we followed the strategy of removing the cranial contour through mathematical morphology. To perform the segmentation we adopted the k-means method. In post-processing, we reverted to using morphology to recover tumor edge features that might have been lost during the segmentation process. Finally, we compared the results obtained visually by superimposing the mask obtained on the original image, thus providing the verification of the tumor region in the two images.

Removal of the cranial region

When analyzing the original images, we noticed that the intensity of the pixels in the skull region are very similar to the corresponding pixels of the tumor. Therefore, this information interferes in the tumor segmentation process, as the algorithm identifies these two intensities as being the same object. Thus, for the step of removing the skull region, Fig. 4, we use the artifice of mathematical morphology as a technique to remove the interference region, applying the morphological erosion operation.

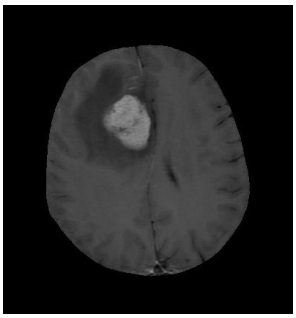

Fig. 4 Image after removal of the cranial region.

Segmentation by k-means

Segmentation is one of the most complex processes in digital image processing, becoming the determining factor for the success of the final system. This tool aims to separate image regions that have similar characteristics, by grouping pixels based on the analysis of basic image attributes. We can delimit this technique into two subdivisions, automatic or semi-automatic segmentations. For this work, we will use automatic segmentation techniques, that is, without external interference in the determination of the regions of interest [8].

The process used for segmentation was k-means, a clustering technique well known for its easy implementation. The selection of objects is based on metrics that analyze each pixel in relation to the distance from a centroid, which in turn are recal- culated at each iteration until reaching the convergence criterion. Thus, at the end of the execution we will have the definition of subgroups of the original image, Fig. 5 [9].

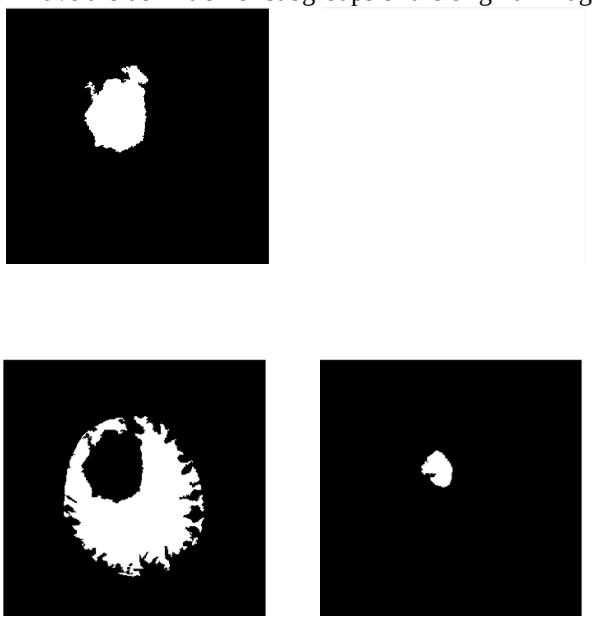

Fig. 5 Clusters obtained from the segmentation by k-means.

Morphological operation

Morphological operations can be used in several context within image processing: both

as information extraction tools to describe a given region, and applied in the pre- and post-processing stages, as is the case with our approach.

In the pre-processing, we use erosion, a morphological filtering technique that results in the reduction or thinning of objects based on the predetermined structuring element, in this case, we take a 30 radius disk [10] as the structuring element.

In post-processing, we apply the closure, Fig. 6. This method tends to smooth the image by filling the discontinuities, consequently closing the holes present in the segmentation result. As a structuring element, a disk with radius 5 was used so that the corrections were as minimal as possible, without adding information on the tumor and changing the correct dimensions of the tumor region [10].

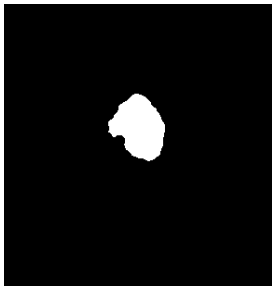

Fig. 6 Mask of the segmented image after morphological closing operation.

Results comparison process

After applying the morphological corrections to the mask of the segmented image, we performed the superposition of this region with the original image, obtaining the result shown in Fig. 7.

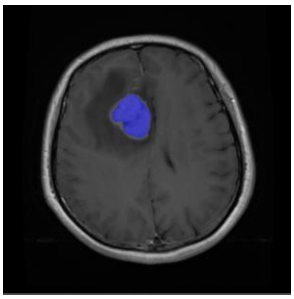

Fig. 7 Final result: superposition of the segmented tumor region over the original image.

3 Results

To evaluate the results, 300 images were analyzed out of a total of 708 that presented a meningioma-type tumor. We then classified the results into three subgroups: segmentation of the correct region with a complete and well-defined tumor (see Fig. 8); segmentation of the correct region, but with some artifact or lack of information at the end of the tumor (see Fig. 9); and segmentation of the incorrect region (see Fig. 10).

For completely correct results, the responses characterized the entire tumor and presented well-defined borders.

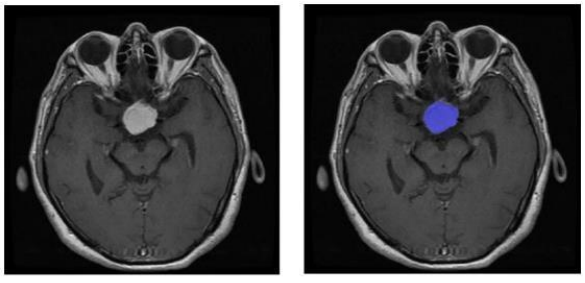

(a) (b)

Fig. 8 (a) Original images; (b) Segmentation of the correct region, with a complete and well-defined tumor.

In some results, we get a partially correct segmentation. In these cases, the correct region was included in the response, but this region was bypassed, usually to an adjacent cranial region that was not completely removed in the process of removing the cranial part.

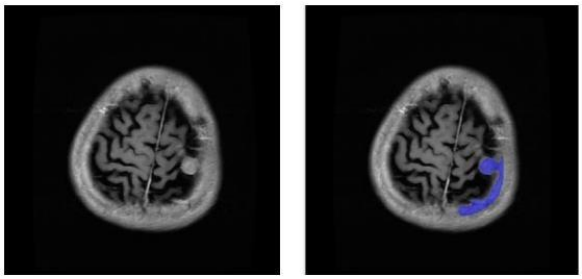

(a) (b)

Fig. 9 (a) Original image; (b) Segmentation of the correct region, but with the presence of an artifact.

In some situations, the results were wrong, targeting a region different from the one of interest. This problem happened in most cases for slices that were in the eye region.

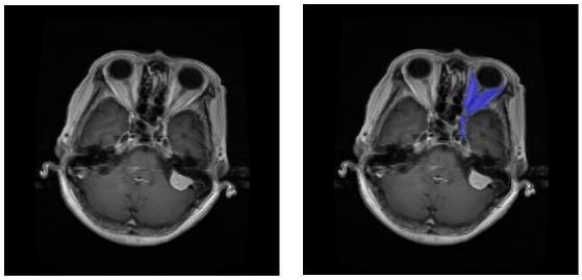

(a) (b)

Fig. 10 (a) Original image; (b) Incorrect segmentation.

The results obtained numerically, Table 1, indicate that 66% of the images were segmented in the characteristic region of the tumor, with 49.67% referring to the complete and well-defined tumor, while 16.33% with the presence of artifacts or missing information on the tumor ends. Consequently, only 34% of the images presented errors in the segmentation region, that is, they did not correspond to the exact location of the pathology.

Table 1. Analysis of algorithm results in magnetic resonance imaging of meningiomas.

Segmentation results	Amount	Percentage
Correct region	149	49.67%
Correct region, but with some kind of flaw	49	16.33%
Incorrect region	102	34%
Total	300	100%

4 Discussion

Analyzing the results obtained, it was observed that the algorithmic strategy developed presented important results for the two types of anatomical cuts present in the image exams in the database. However, the responses were more satisfactory for the transverse sections when compared to the coronal ones, this may be due to the amount of information from the two images, since the coronal section presents many artifacts

related to the neck region and cranial base.

Other conclusions associated with our tests are precisely in the evaluation of slices that are located very close to the eye region or that have a very thick braincase, that is, those that the first stage of skull removal were not as effective due to their thickness. These flaws must be circumvented, since both additional information and the lack of precision in the size of the lesion can lead to false diagnoses and impair the patient's treatment.

In the cases analyzed by the authors in [11] and [12] with a similar strategy, the techniques of filtering, k-means, thresholding and CNN were used, which obtained the correct percentages of 89.23% and 90.03%, respectively. In the work developed in [5] for computed tomography images, the authors used the techniques of edge recognition filters, morphological operations and segmentation, reaching an accuracy of 94.23%.

In the previous situations, when comparing the results of each algorithm with the 66% obtained in this work, they seem to be significantly better results, however, we must consider the difference between the processing techniques and the amount of images applied for testing. Another important factor to be evaluated was the diversity of slice planes for the resonance images used in this study, which directly interfered with our results and suggest future improvements in the implemented algorithm, in order to encompass the greatest variability of possible cases.

However, in general, the results were interesting, since the algorithm was able to accurately pinpoint the location of the tumor in more than half of the images, needing only a few adjustments to completely hit the 16.33% that included some artifact or ignored some pixels from the edge of the tumor.

5 Conclusion

The results obtained demonstrate that the system presents satisfactory results in the diversity of images to which it is submitted, correctly segmenting the region of interest and with a well-defined delimitation of the ends for most cases.

However, in situations with great diversity of information, mainly in the region of the eyes and cuts that cover the neck and cranial base, the system does not present a good performance. In these cases, the segmentation occurs in the correct positions, however, they suffer interference with the addition of artifacts or loss of pixels referring to the edges of the tumor. In these circumstances, the system needs to undergo a review to refine the segmentation, due to the need for precision in the results in order to avoid errors in the diagnosis or inconsistency in the regions presented.

As future work, the algorithm can be improved in order to improve accuracy and reduce error cases. Use of the deep learning technique, as well as the qualitative evaluation of the results by experts in the area.

Acknowledgment

The authors thank the Laboratory of Medical Signs and Images (LabSIM) of the Federal University of Rio Grande do Norte for their support in this research.

Conflict of interests

The authors declare no conflict of interest.

References

1. MENDES, Graziella Alebrant; ONGARATTI, Bárbara Roberta e PEREIRA-LIMA, Júlia Fernanda Semmelmann. Epidemiologia de uma série de tumores primários do Sistema nervosa central [Epidemiology of a series of primary tumors of the central nervous system; In Portuguese]. **Arq. Bras. Neurocir.** 33(4): 279-83, (2014).
2. BRASIL. **Ministério da Saúde. Secretaria de Atenção à Saúde.** Consulta pública n° 30,

de 19 de Agosto de 2010 [Public consultation n° 30, of August 19, 2010; In Portuguese]. Disponível em: https://bvsms.saude.gov.br/bvs/saudelegis/sas/2010/cop0030_19_08_2010.html. Acesso em: 17 de junho de 2022.

3. HAGE, Maria Cristina Ferrarini Nunes Soares; IWASAKI, Masao. Imagem por ressonância magnética: princípios básicos [Magnetic resonance imaging: basic principles; In Portuguese]. **Ciência Rural**, Santa Maria, v.39, n.4, p.1287-1295, jul 2009.
4. ARAGÃO, Maria de Fátima Viana Vasco. A ressonância magnética em tumores astrocitários: avaliação da associação de padrão existente com a graduação histopatológica [Magnetic resonance imaging in astrocytic tumors: assessment of the association of existing pattern with histopathological grading; In Portuguese]. 2010. 140 f. Tese (doutorado) – Universidade Federal de Pernambuco. CCS. Neuropsiquiatria e Ciências do Comportamento, 2010.
5. SONI, Akanksha e RAI, Avinash. CT Scan Based Brain Tumor Recognition and Extraction using Prewitt and Morphological Dilation. **International Conference on Computer Communication and Informatics** (ICCCI – 2021), Coimbatore, India.
6. **Instituto Nacional de Câncer (INCA).** Câncer do Sistema Nervoso Central [Cancer of the Central Nervous System; In Portuguese]. 25 de Abril de 2022. Disponível em: <https://www.inca.gov.br/tipos-de-cancer/cancer-do-sitema-nervoso-central>. Acesso em: 17 de junho de 2022.
7. Cheng J, Huang W, Cao S, Yang R, Yang W, Yun Z, et al. (2015) Enhanced Performance of Brain Tumor Classification via Tumor Region Augmentation and Partition. **PLoS ONE** 10(10):e0140381. doi:10.1371/journal.pone.0140381.
8. SILVA, Ana Maria Marques da; PATROCÍNIO, Ana Cláudia e SCHIABEL, Homero. Processamento e Análise de Imagens Médicas [Processing and analysis of medical images; In Portuguese]. **Revista Brasileira de Física Médica.** (2019); 13(1):34-48.
9. JÚNIOR, Daniel Elídio Mendes. **Utilização do algoritmos k-means na segmentação e classificação de imagens de refeições [Use k-means algorithms in the segmentation and classification of images of meals; In Portuguese].** 2015. 75 f. Monografia – Univer- sidade Federal de Alfenas, Curso de Bacharelado em Ciências da Computação, 2015.
10. Gonzales, Rafael C. **Processamento digital de imagens [Digital image processing; In Portuguese]** / Rafael C. Gonzales e Richard C. Woods; revisão técnica: Marcelo Vieira e Maurício Escarpinati; [tradução Cristina Yamagami e Leonardo Piamonte]. –3. Ed. –São Paulo: Pearson Prentice Hall, 2010.
11. MASCARENHA, Layse Ribeiro; JÚNIOR, Audenor dos Santos Ribeiro e RAMOS, Rodrigo Pereira. Segmentação automática de tumores cerebrais em imagens de ressonância magnética [Automatic segmentation of brain tumors in MRI images; In Portuguese]. **Einstein (São Paulo)** - 2020. https://doi.org/10.31744/einstein_journal/2020AO4948.
12. KHAN, Amjad Rehman; KHAN, Siraj; HAROUNI, Majid; ABBASI, Rashid; IQBAL, Sajid e MEHMOOD, Zahid. Brain tumor segmentation using k-means clustering and deep learning with synthetic data augmentation for classification. **Microscopy Research and Technique.** February, 2021. DOI:10.1002/jemt.23694.