



**ARTIFICIAL INTELLIGENCE APPLIED TO
THE DIAGNOSIS OF BRAIN NEOPLASMS**

EDILAINE GONÇALVES COSTA DE FARIA

Advisers: Francisco Assis de Oliveira Nascimento, Phd (UnB)
and Cristiano Jacques Miosso, Phd (UnB)

**DOCTORAL DEFENSE DISSERTATION
IN ELECTRICAL ENGINEERING**

**DEPARTAMENT OF ELECTRICAL ENGINEERING
FACULDADE DE TECNOLOGIA**

UNIVERSIDADE DE BRASÍLIA

Universidade de Brasília
Faculdade de Tecnologia
Department of Electrical Engineering

Artificial Intelligence Applied to the Diagnosis of Brain Neoplasms

Edilaine Gonçalves Costa de Faria

DOCTORAL DEFENSE DISSERTATION SUBMITTED TO THE GRADUATE
PROGRAM IN ELECTRICAL ENGINEERING AT THE UNIVERSITY OF BRASÍLIA
AS PART OF THE REQUIREMENTS FOR THE DOCTORAL DEGREE.

APPROVED BY:

Francisco Assis de Oliveira Nascimento, PhD (UnB)
(Adviser)

Fábio Henrique Monteiro Oliveira, PhD (IFB)
(External Examiner)

André Coutinho Castilla, PhD
(External Examiner)

Adson Ferreira da Rocha, PhD (UnB)
(Internal Examiner)

Brasília/DF, February 2026.

CATALOG CARD

FARIA, EDILAINÉ GONÇALVES COSTA DE

Artificial Intelligence Applied to the Diagnosis of Brain Neoplasms. [Brasília/DF] 2026. PPGEE 218/25, 188p., 210 x 297 mm (ENE/FT/UnB, Doctor, Doctoral Defense Dissertation, 2026).

University of Brasília, Faculty of Technology, Department of Electrical Engineering.

Department of Electrical Engineering

- | | |
|----------------------|-------------------------------|
| 1. Brain Neoplasms | 2. Magnetic Resonance Imaging |
| 3. Machine Learning | 4. Deep Learning |
| 5. Data Augmentation | 6. Transfer Learning |
| I. ENE/FT/UnB | II. Title (series) |

BIBLIOGRAPHIC REFERENCE

FARIA, EDILAINÉ GONÇALVES COSTA DE (2026). Artificial Intelligence Applied to the Diagnosis of Brain Neoplasms. Doctoral Defense Dissertation, Publication PPGEE 218/25, Department of Electrical Engineering, University of Brasília, Brasília, DF, 188p.

COPYRIGHT AUTHORIZATION

AUTHOR: Edilaine Gonçalves Costa de Faria

TITLE: Artificial Intelligence Applied to the Diagnosis of Brain Neoplasms.

DEGREE: Doctor YEAR: 2026

Permission is granted to the University of Brasília to reproduce copies of this Doctoral Defense Dissertation and to lend or sell such copies only for academic and scientific purposes. The author reserves other publication rights, and no part of this Doctoral Defense Dissertation may be reproduced without the author's written permission.

Edilaine Gonçalves Costa de Faria

University of Brasília (UnB)

Darcy Ribeiro Campus

Faculty of Technology - FT

Department of Electrical Engineering(ENE)

Brasília - DF CEP 70919-970

ACKNOWLEDGMENTS

I would first like to thank God for granting me strength and wisdom throughout the development of this work.

I am grateful to my family, especially my mother, father, sister, and niece, for their encouragement and support. I also extend my gratitude to my friends and healthcare professionals who stood by me, offering understanding and assistance during the doctoral period.

I must thank the *Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES)* for granting the scholarship through the Social Demand Program.

I am thankful to Professors Francisco Assis and Cristiano Jacques Miosso for their guidance and valuable contributions. I also extend my appreciation to the other faculty members of the University of Brasília (UnB) for sharing their knowledge throughout the program.

I appreciate my colleagues and professors who contributed to the development of this research, especially the members of the Machine Learning Group (MLG).

Finally, I thank the examination committee members for their availability, suggestions, and insightful contributions that enriched this study.

ABSTRACT

The medical evaluation of Magnetic Resonance Imaging (MRI) is aimed at preventing possible complications caused by brain neoplasms, and this diagnostic method has become increasingly optimized due to technological advances. Therefore, with these advances and the objective of automating this procedure to assist physicians, this work focused on investigating the development of algorithms to support the diagnosis of brain neoplasms. In this study, it is investigated whether the performance metrics of the developed system are capable of identifying three different types of brain neoplasms in MRI images, namely, meningioma, glioma, and pituitary adenomas, with values superior to those reported in the scientific literature, considering the lowest possible computational cost.

Several solutions based on training are reported in the literature, yet relatively few studies systematically compare their performance in scenarios involving smaller datasets, considering models of varying complexity and distinct data augmentation techniques. Hence, this study investigates the development of an MRI brain neoplasm classification system, including scenarios in which the amount of data is smaller than that commonly reported in the literature. The different deep learning strategies explored were data augmentation with traditional and pre-trained models; feature extraction followed by classification; and transfer learning in restricted data scenarios, as well as using Generative Adversarial Networks for generating training images.

The obtained results were comparable to those reported in the literature. The network trained with augmented data, using flip and noise transformations and only the axial slice, developed from a pretrained architecture, achieved an accuracy of 88.4%, precision of 84.3%, recall of 84.9%, and F-score of 84.6%. Deep learning models employing transfer learning achieved superior results, reaching an accuracy of up to 96.8%; in this case, precision reached 96.8%, recall 94.8%, and F-measure 95.6%, using DenseNet121. Consequently, the employed strategies are efficient for this application in supporting the diagnosis of brain neoplasms.

The models trained with images generated by a Generative Adversarial Network did not achieve results superior to those obtained with real images. Nevertheless, the results are expres-

sive according to the literature, indicating that such synthetic image generation can be applied in studies involving brain neoplasm classification systems. Therefore, further exploration of this approach in MRI image analysis is one of the proposed directions for future work. In addition, another possible line of future research would be to analyze the complexity of the proposed strategies, including processing requirements and energy consumption, which would be valuable for the development of embedded systems.

In summary, among the strategies evaluated in this study, transfer learning proved to be the most effective, because its generalizability and the stability of the obtained results ensure superior performance across all evaluated metrics. This demonstrates that such an approach can extract relevant features even in a scenario involving only axial slice images. Hence, this study confirms the effectiveness of advanced deep learning architectures in supporting automated image-based diagnosis, even when dealing with limited datasets. Therefore, there has been a significant advancement in supporting the diagnosis of brain neoplasms, contributing to faster and more accurate clinical decisions, which may also be achieved through incidental findings. Furthermore, such strategies can also be applied to other types of brain imaging diagnoses.

Keywords: Brain Neoplasms, Magnetic Resonance Imaging, Feature Extraction, Classification, Machine Learning, Deep Learning, Transfer Learning, Generative Adversarial Network.

RESUMO

Título: Inteligência Artificial Aplicada ao Diagnóstico de Neoplasias Cerebrais

A avaliação médica de Imagens de Ressonância Magnética, do inglês - *Magnetic Resonance Imaging (MRI)*, para evitar possíveis complicações geradas por neoplasias cerebrais, é um dos métodos de diagnóstico e que se tornou mais otimizado devido aos avanços tecnológicos. Portanto, com esses avanços e o objetivo de automatizar esse procedimento para auxiliar os médicos, este trabalho concentrou-se em investigar o desenvolvimento de algoritmos para auxiliar no diagnóstico de neoplasias cerebrais. Neste estudo, é investigado se medidas de desempenho de um sistema desenvolvido é capaz de identificar três tipos diferentes de neoplasias cerebrais de MRI, sendo meningioma, glioma e adenomas de hipófise, com valores superiores aos apresentados na literatura científica, considerando o menor custo computacional possível.

Diversas soluções baseadas em treinamento existem na literatura, mas há relativamente poucos estudos comparando, de forma sistemática, o desempenho em cenários com bases menores, levando em conta modelos de diferentes complexidade e diferentes técnicas de aumento de dados. Diante disto, este estudo consiste em investigar o desenvolvimento de um sistema classificador de MRI de neoplasias cerebrais, inclusive em situações em que o número de dados é relativamente menor em comparação com as quantidades de dados apresentadas na literatura. Logo, neste estudo, foram utilizadas diferentes estratégias de aprendizagem profunda, tais como aumento de dados com modelos tradicionais e pré-treinados, extração de características seguida da classificação e transferência de conhecimento em cenários com números restritos de dados, além de uso de Rede Adversária Generativa para geração de imagens de treinamento.

Os resultados obtidos ficaram próximos aos resultados da literatura. A rede com aumento de dados, utilizando flip e ruído e utilizando apenas o corte axial, desenvolvida a partir de uma arquitetura pré-treinada, alcançou o resultado com acurácia de 88,4%; precisão de 84,3%; *recall* de 84,9%; e f-score de 84,6%. O uso de aprendizado profundo em modelos de transferência de conhecimento proporcionou melhores resultados, com uma acurácia de até 96,8%, neste caso a precisão resultou em 96,8%, *recall* em 94,8% e medida-F em 95,6%, utilizando Densenet 121.

Logo, como resultado, determinou-se que as estratégias empregadas são eficientes para esta aplicação de auxílio a diagnóstico de neoplasias cerebrais.

Além disso, com imagens geradas por Rede Adversária Generativa para o treinamento das redes não foram alcançados resultados superiores aos obtidos com imagens reais. Apesar disso, os resultados são expressivos, segundo a literatura, indicando que é possível utilizar esse tipo de geração de imagens em estudos sobre sistema classificador de neoplasias cerebrais. Logo, o aprofundamento deste tipo de aplicação em MRI é uma das propostas de trabalho futuro. Além disso, outro possível trabalho futuro, seria analisar a complexidade das estratégias, processamento e consumo de energia, sendo útil no desenvolvimento de sistemas embarcados.

Em síntese, dentre as estratégias avaliadas neste estudo, transferência de conhecimento mostrou-se a mais eficiente, destacando-se sobretudo pela capacidade de generalização e pela estabilidade dos resultados obtidos, garantindo desempenho superior em todas as métricas avaliadas, evidenciando que essa abordagem é capaz de extrair características relevantes mesmo em um cenário de imagens apenas do corte axial. Portanto, este trabalho confirma a efetividade do uso de arquiteturas avançadas de aprendizagem profunda para o auxílio a diagnóstico por imagem automatizado, inclusive em situações de quantidades restritas de imagens. Logo, houve um avanço significativo no suporte ao diagnóstico de neoplasias cerebrais, contribuindo para decisões clínicas mais rápidas, precisas e, também, podendo ser obtidas por meio de um achado incidental. Além disso, tais estratégias podem, inclusive, ser aplicadas em outros tipos de diagnósticos de imagens cerebrais.

Palavras-chave: Neoplasias Cerebrais, Imagem de Ressonância Magnética, Extração de Características, Classificação, Aprendizado de Máquina, Aprendizado Profundo, Transferência de Conhecimento, Rede Adversária Generativa.

TABLE OF CONTENTS

List of Figures	iii
List of Tables	vii
Glossary	x
Chapter 1 – Introduction	1
1.1 Contextualization	1
1.2 Scientific Problem Definition and Proposal	3
1.3 Objectives	4
1.3.1 General Objective	4
1.3.2 Specific Objectives	5
1.4 Justification and Contributions	5
Chapter 2 – Theoretical Foundation	7
2.1 Medical-Scientific Foundation	7
2.1.1 Historical Evolution of Brain Neoplasms	7
2.1.2 Global Epidemiology of Central Nervous System Neoplasms	11
2.1.3 Types of Brain Neoplasms	13
2.1.4 Medical Imaging Acquisition Modalities	16
2.2 Artificial Intelligence	18
2.2.1 Historical Factors in the Evolution of Artificial Intelligence	19
2.2.2 Examples of Classifiers	21
2.2.3 Some Applications of Machine Learning in the Literature	23
2.2.4 Generative Adversarial Network	24
Chapter 3 – Materials and Methods	27
3.1 Database	27
3.1.1 Figshare - 3 Classes	27
3.2 CNN using Data Augmentation – Strategy 1	29
3.2.1 All Three Slices	30

3.2.2	Axial Slice Only	31
3.3	Feature Extraction Using Convolutional Neural Networks - Strategy 2	32
3.4	Transfer Learning - Strategy 3	34
3.5	Generative Adversarial Network	36
3.6	Metrics Used in Performance Evaluation	37
Chapter 4 – Results and Discussion		41
4.1	Data Augmentation Techniques - Strategy 1	41
4.2	Classification of Feature Extraction Using CNN (Axial Slice Only) - Strategy 2 .	46
4.3	Transfer Learning (Axial Slice Only) - Strategy 3	47
4.4	Generative Adversarial Network	54
4.5	Scientific Research Addressed in the State of the Art	56
4.6	General Discussion of the Results	58
Chapter 5 – Conclusion		62
References		63
.1	Appendix A	73

LIST OF FIGURES

2.1	Numbers of deaths related to Central Nervous System (CNS) tumors in Brazil in 2020 and 2022.	13
2.2	Examples of brain neoplasm images: Left - Meningioma, Middle - Glioma, Right - Pituitary adenoma	15
2.3	Examples of the three MRI slices from different patients (left: sagittal, middle: axial, right: coronal).	17
3.1	Block diagram of the convolutional layers of the CNN network using images from all three slices. This network has three sequences of convolutional, maxpooling, and dropout layers, followed by one flatten layer, one dense layer, another dropout, and a final dense layer.	31
3.2	Block diagram of the convolutional layer stages of the pretrained CNN network (VGG16) using images from the three different slices. This network consists of a sequence of convolutional, batch normalization, maxpooling, global average pooling, dropout, and dense layers.	31
3.3	Block diagram of the convolutional layers in the CNN model using only axial slices. This network is composed of three sequences of convolutional and maxpooling layers, followed by one global average pooling, one dense, one dropout, and a final dense layer.	32
3.4	Block diagram of the convolutional layers in the pretrained CNN (VGG16) model using only axial slices. This network is composed of a sequence of global average, dropout, and dense layers.	33

3.5	Block diagram of the convolutional layers in the CNN Transfer Learning model using only axial slices. This network consists of a global average pooling layer, two sequences of dense, batch normalization, and dropout layers, followed by a final dense layer.	34
3.6	Block diagram of the convolutional layers in the GAN generator model used (Dense, BatchNormalization, LeakyReLU, Reshape, and multiple Conv2DTranspose layers and Conv2DTranspose layer).	36
3.7	Block diagram of the convolutional layers in the GAN discriminator model used (Conv2D, LeakyReLU, Dropout, Flatten, and Dense layers).	36
3.8	Flowchart representing how T_P , F_P and F_n are found.	38
4.1	Training (blue) and validation (orange) results obtained by the CNN using images from all slices, without data augmentation. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is presented as a function of the epoch.	41
4.2	Training (blue) and validation (orange) results obtained by the pretrained CNN using images from all slices, without data augmentation. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is presented as a function of the epoch.	43
4.3	Training (blue) and validation (orange) results obtained by the CNN using only the axial slice, without data augmentation. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is presented as a function of the epoch.	43
4.4	Training (blue) and validation (orange) results obtained by the CNN using only the axial slice, with data augmentation using flip. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is presented as a function of the epoch.	44

-
- 4.5 Training (blue) and validation (orange) results obtained by the CNN using only the axial slice, with data augmentation using flip and noise. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is presented as a function of the epoch. 44
- 4.6 Training (blue) and validation (orange) results obtained by the pretrained CNN using only the axial slice, without data augmentation. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is presented as a function of the epoch. 45
- 4.7 Training (blue) and validation (orange) results obtained by the pretrained CNN using only the axial slice, with data augmentation using flip. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is presented as a function of the epoch. 45
- 4.8 Training (blue) and validation (orange) results obtained by the pretrained CNN using only the axial slice, with data augmentation using flip and noise. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is presented as a function of the epoch. 46
- 4.9 Training and validation results obtained through Transfer Learning using DenseNet121 and only the axial slice. In ‘(a)’ is the accuracy as a function of epochs, and in ‘(b)’ is the loss function as a function of epochs. 51
- 4.10 Confusion matrix obtained for the DenseNet121 model using Transfer Learning , in percentage (%). Axial slice with three distinct classes: meningioma, glioma, and pituitary adenomas. 51
- 4.11 Training and validation results obtained through Transfer Learning using MobileNet and only the axial slice. ‘(a)’ exhibits the accuracy as a function of epochs, and ‘(b)’ presents the loss function as a function of epochs. 52
- 4.12 Training and validation results obtained through Transfer Learning EfficientNetV2 B0 and only the axial slice. ‘(a)’ exhibits the accuracy as a function of epochs, and ‘(b)’ presents the loss function as a function of epochs. 52

4.13	Training and validation results obtained through Transfer Learning Inception V3 and only the axial slice. ‘(a)’ exhibits the accuracy as a function of epochs, and ‘(b)’ presents the loss function as a function of epochs.	53
4.14	Training and validation results obtained through Transfer Learning using Xception and only the axial slice. ‘(a)’ exhibits the accuracy as a function of epochs, and ‘(b)’ presents the loss function as a function of epochs.	53
4.15	Graph of the results obtained from image generation using a Generative Adversarial Network showing the loss as a function of the epoch.	54
4.16	Examples of the three MRI classes generated by the GAN from different patients (left: meningioma; center: glioma; right: pituitary adenoma).	55
4.17	Training (blue) and validation (orange) results obtained by the pretrained CNN using only the axial slice. ‘(a)’ accuracy shows as a function of the epoch, and ‘(b)’ presents the loss function as a function of the epoch.	56

LIST OF TABLES

3.1	Characteristics of the database (CHENG, 2017) as referenced in (CHENG <i>et al.</i> , 2015).	28
3.2	Number of features (divided into training and testing sets) extracted by each deep learning architecture.	33
3.3	Classifiers and their parameters used in this work under Strategy 2. All from the scikit-learn package (PEDREGOSA <i>et al.</i> , 2011).	34
3.4	Number of test images per class: class 1 represents meningioma tumors, class 2 glioma, and class 3 pituitary adenoma. Approximately 80% were used for training (20% of which were separated for validation) and 20% for testing for each slice (axial, sagittal, and coronal). Strategy 3.	35
3.5	Number of test images per class: class 1 represents meningioma tumors, class 2 glioma, and class 3 pituitary adenoma. Approximately 80% were used for training (10% of which were separated for validation) and 20% for testing. Strategy 3.	36
3.6	Number of test, training, and validation images per class, where class 1 corresponds to meningioma, class 2 to glioma, and class 3 to pituitary adenoma for approach of GAN. Of the images generated by the GAN, 20% were used for validation and 80% for training.	37
4.1	Performance metrics for the classification of brain neoplasms from MRI images using customized and pretrained CNNs, including cases with data augmentation. Results are shown for all slices and for the axial slice only.	42

4.2	Average performance metrics for classifications using DenseNet121 to extract features. Classification without dimensionality reduction. Total execution time (training and testing): 4 minutes and 6 seconds.	47
4.3	Average performance metrics for classifications using DenseNet121 to extract features. Classification with dimensionality reduction. Total execution time (training and testing): 1 minute and 14 seconds.	48
4.4	Average performance metrics for classifications using MobileNet to extract features. Classification with dimensionality reduction.	48
4.5	Average performance metrics for classifications using EfficientNet V2 B0 to extract features. Classification with dimensionality reduction.	48
4.6	Average performance metrics for classifications using Inception V3 to extract features. Classification with dimensionality reduction.	49
4.7	Average performance comparison of classifiers using Xception to extract features. Classification without dimensionality reduction. Execution time of each classifier in seconds. Total execution time (training and testing): 7 minutes and 12 seconds.	49
4.8	Average performance comparison of classifiers using Xception to extract features. Classification with dimensionality reduction. Execution time of each classifier in seconds. Total execution time (training and testing): 1 minute and 19 seconds.	49
4.9	Performance metrics for the classification of brain neoplasms (glioma, meningioma, and pituitary adenomas) in magnetic resonance images using Transfer Learning (DenseNet121) for each slice separately (axial, sagittal, coronal).	50
4.10	Performance metrics for brain neoplasm classification (glioma, meningioma, and pituitary adenomas) in magnetic resonance images using Transfer Learning.	50
4.11	Performance metrics for the classification of brain neoplasms (glioma, meningioma, and pituitary adenoma) in MRI images using images generated by a Generative Adversarial Network with a pre-trained network strategy (Section 4.1).	55

4.12 Studies using the dataset (CHENG, 2017) for MRI-based classification of three diseases (meningioma, glioma, and pituitary adenoma) — showing the best average accuracy (%) and the type of models used.	61
--	----

GLOSSARY

AI	Artificial Intelligence
ANN	Artificial Neural Networks
Bagg	Bagging Classifier
CNN	Convolutional Neural Network
CNS	Central Nervous System
CT	Computed Tomography
DC-ELM	Deep Intense Normal Machine Learning
DICOM	Digital Imaging and Communications in Medicine
DL	Deep Learning
DBM	Deep Boltzmann Machine
DBN	Deep Belief Network
DNN	Deep Neural Network
DT	Decision Tree Classifier
ET	Extra Trees Classifier
GAN	Generative Adversarial Network
GNB	Gaussian Naive Bayes
INCA	National Cancer Institute, in Portuguese, <i>Instituto Nacional do Câncer</i>
INPI	<i>Instituto Nacional da Propriedade Industrial</i>
KNN	K Neighbors Classifier
ML	Machine Learning

MLP	Multilayer Perceptron
MRI	Magnetic Resonance Imaging
QDA	Quadratic Discriminant Analysis
RF	Random Forest Classifier
RGB	Red, Green and Blue
RL	Reinforcement Learning
RNN	Recurrent Neural Networks
SGDC	Stochastic Gradient Descent Classifier
SVM	Support Vector Machine

1.1 CONTEXTUALIZATION

Employing the advances of Artificial Intelligence (AI) applied to automation, this study focused on investigating the development of algorithms to assist in diagnosing brain neoplasms. Brain neoplasms consist of abnormal and uncontrolled proliferation of cells in brain tissue and may be benign or malignant; in the latter case, they correspond to cancer. This study is relevant because it allows classification without the specialist's participation during a screening process. Then, severe cases can be referred to a specialist for evaluation. This approach is used in studies that apply machine learning techniques to Magnetic Resonance Imaging (MRI) data, aiming to automate the diagnostic procedure.

In the past, brain neoplasms (examples are shown in Figure 2.2) were poorly understood and often associated with mysterious or spiritual causes. Due to the lack of technology at that time, surgeries to remove brain neoplasms were rare and risky. However, with the advent of modern medical technology, techniques for detecting and removing brain neoplasms have improved, reaching the current stage of MRI analysis, including automated detection strategies using AI.

According to the Brazilian National Cancer Institute (INCA), neoplasms of the Central Nervous System (CNS) represent approximately 1.4% to 1.8% of malignant tumors worldwide (INCA, 2022). These percentages highlight the global health impact of this disease and the importance of detecting it at early stages whenever possible. Furthermore, due to its potentially fatal nature, early diagnosis plays a crucial role in the effective treatment of brain neoplasms, helping to prevent and reduce the number of affected individuals.

The two main strategies for detecting brain neoplasms are: invasive and noninvasive methods. The first involves a biopsy, while the latter includes imaging exams such as Computed

Tomography (CT) and MRI (TANDEL *et al.*, 2019). Therefore, employing fast and efficient strategies is essential for early diagnosis to prevent disease progression and the consequences of this condition.

Several studies, including recent ones, present this type of analysis (DORFNER *et al.*, 2025; MA, 2025; KUMAR, 2025; ZHANG *et al.*, 2025; YANG *et al.*, 2024; LAKSHMI *et al.*, 2025; MUGDHA; UDDIN, 2025). For instance, one study reviews the architecture of Convolutional Neural Networks (CNN) for image classification and focuses on the analysis of relevant data for the diagnosis of brain neoplasms through MRI (HASAN *et al.*, 2023). Another study compares different deep learning architectures in the state of the art (ANAGUN, 2023), while others evaluate the use of transfer learning in similar applications (SACHDEVA *et al.*, 2024; ALBALAWI *et al.*, 2024). Further research investigates meningioma detection in brain neoplasms (ANITA; KUMARAN, 2022), and another study evaluates the case of tumor versus non-tumor classification (ARUMUGAM *et al.*, 2024).

Moreover, transfer learning networks, such as Visual Geometry Group 16 (VGG16), Inception V3, ResNet-101, and DenseNet-201 have been used to extract features from brain MRI images (WAGEH *et al.*, 2024). Another study employed the following architectures: VGG16, InceptionV3, VGG19, ResNet50, InceptionResNetV2, and Xception (HOSSAIN *et al.*, 2024). In another work using VGG-16, VGG-19, Inception-v3, ResNet-50, DenseNet, and MobileNet, the authors concluded that VGG-16 achieved the best results (SHAMSHAD *et al.*, 2024). Additionally, another article mentioned the use of transfer learning techniques associated with data augmentation networks (*Generative Adversarial Network (GAN)*) (NAG *et al.*, 2024).

Despite these studies, no in-depth comparisons of specific classifiers for MRI images were found in the scientific literature under the same conditions, parameters, and with a reduced number of images from the same dataset used in this work. Therefore, this study investigated the development of a brain neoplasm detection system, which requires machine learning techniques to compare different classifiers, such as CNNs, given their frequent use in the literature and their notable performance results (such as, for example, accuracy above 90%).

Furthermore, the strategies implemented include custom and pre-trained networks; testing the influence of data augmentation during training; feature extraction by CNN followed by classification; transfer learning; and GANs for generating images used in network training. These

strategies aim to improve the results obtained, considering the simplest possible CNN architectures that can be trained with smaller datasets, compared to the literature, while achieving promising performance results, consistent with those reported in state-of-the-art research.

1.2 SCIENTIFIC PROBLEM DEFINITION AND PROPOSAL

According to several studies, the process of detecting brain neoplasms is relatively challenging due to the wide variety of neoplasms in different patients and their similarity to healthy tissues (ARIF *et al.*, 2022). In addition, it is essential to analyze several features, such as variations in tumor location, shape, and size (AMIN *et al.*, 2022).

Given the importance of early diagnosis, exploring alternative methods for brain neoplasm detection is relevant. The idea is that detection could even occur during a screening stage. To automatically detect brain neoplasms, machine learning techniques applied to medical images can be used. One of these techniques is the CNN, a type of deep learning model. Deep learning has become predominant in the field of machine learning, including applications related to brain imaging (SCHULZ *et al.*, 2020; KHAN *et al.*, 2022; NAYAK *et al.*, 2022; TANDEL *et al.*, 2019).

After a systematic review of the scientific literature, it was observed that several solutions have been proposed based on training with datasets containing a relevant number of images compared to this study, many of which report accuracy, specificity, precision, and sensitivity values above 90%. However, there are relatively few studies that systematically compare performance in scenarios involving smaller datasets, analyzing only a single slice, while considering models of varying complexity and different data augmentation techniques.

Therefore, this study aims to investigate a classifier system for MRI, focusing on brain neoplasm images, since previous studies have shown relevant performance (such as, for example, accuracy above 90%) for this type of analysis. Several strategies will be implemented to improve the results reported in the literature, considering the simplest possible CNN architectures that can be trained with smaller datasets. This includes analyzing different data augmentation techniques to enhance performance metrics when working with a reduced number of images from the database used (CHENG, 2017).

This work proposes to investigate how well these automated classifications can be trained,

even when using a single slice (see Figure 2.3) to improve the efficiency of classifiers and reduce computational cost. Furthermore, the contribution of this study lies in identifying which architecture achieves the best performance, such as classification developed using a custom architecture and pre-trained network (Strategy 1), feature extraction using CNNs (Strategy 2), and transfer learning (Strategy 3). Additionally, GAN will be employed to produce images for training some of the best-performing models.

In this context, to determine the best classification strategy, analyses of the results were conducted using metrics such as accuracy, precision, recall, and F-measure. Accuracy is defined as the proportion of correct predictions relative to the total number of cases; precision measures, among the cases predicted as class x , how many truly belong to class x ; recall indicates, among the cases that actually belong to class x , how many were correctly identified; and the F-measure is the harmonic mean between precision and recall.

These metrics were selected because they are commonly used in the literature, especially in the medical field. Since false negatives are the most critical errors in medicine, the recall metric evaluates this type of situation, helping to prevent severe cases from being overlooked. When used in isolation, these metrics may lead to misinterpretation of results; therefore, when analyzed together, they more accurately reflect the practical impact of their application in the medical context.

By evaluating these metrics, this study aims to investigate and identify the best strategies for classifying brain diseases in MRI images with the highest performance results, potentially applicable during diagnosis, screening, or incidental findings.

1.3 OBJECTIVES

1.3.1 General Objective

To investigate the development of a medical diagnosis support system using classification models with performance values superior to those achieved in the literature, based on different classifiers of MRI of the brain from different slices, related to the detection of brain neoplasms. This includes the use and comparison of various machine learning techniques, while

selecting architectures that can be trained with smaller datasets, compared to those reported in the literature.

1.3.2 Specific Objectives

- 1 To investigate the development of an automated system to support MRI-based medical diagnosis through a case study involving the analysis of brain images of neoplasms (meningioma, glioma, and pituitary adenomas).
- 2 To explore automatic classification approaches for brain neoplasms in MRI using deep learning strategies, such as traditional data augmentation techniques, pre-trained networks, feature extraction models based on CNN, and transfer learning, including employing the smallest possible dataset, in addition to using GAN for generating training images for the networks.
- 3 To compare the performance metrics of different classifier systems that detect brain neoplasms using MRI, by employing evaluation metrics such as accuracy, precision, recall, and F-measure, selecting architectures that achieve the best results and can be trained with smaller datasets.

1.4 JUSTIFICATION AND CONTRIBUTIONS

Currently, the state of the art presents the use of AI for the detection of brain neoplasms in MRI as a tool to support medical diagnosis, which can be applied in screening processes or in the identification of incidental findings. Automatic classification of MRI images poses several challenges, such as the computational cost, mainly caused by CNNs (AKINYELU *et al.*, 2022), and the need for a large volume of data to properly train learning models. Despite these challenges, deep learning generally produces superior performance results compared to other techniques.

Investigating machine learning techniques that can achieve performance comparable to the state of the art is important under these challenging conditions. Several solutions in the scientific literature use datasets with a larger number of images compared to this study and even

report performance metrics exceeding 90%. However, there are relatively few studies that systematically compare performance by evaluating models of different complexities and different data augmentation techniques, particularly in scenarios involving smaller numbers of images relative to those commonly used in the literature.

Therefore, this work proposes to investigate the classification of different types of brain neoplasms, including meningioma, glioma, and pituitary adenomas, using images selected from only one slice, aiming to reduce computational cost and simplify the strategies used, while maintaining a sufficient number of images to achieve expressive performance, according to the literature. Furthermore, this study applies several data augmentation approaches to develop systems with superior performance metrics.

This involves the systematic evaluation of various machine learning tools to obtain satisfactory classification results, in accordance with the literature, particularly CNNs, which are frequently used. They perform automatic feature extraction and classification with relevant results, according to the state of the art.

In summary, this research focuses on investigating a tool to support medical diagnosis through a non-invasive method for detecting brain neoplasms. In addition to contributing to early diagnosis, it facilitates detection, which may even occur during screening or as an incidental finding, consequently improving patients' quality of life, since early diagnosis enables early treatment.

Therefore, the study aims to select the simplest possible architectures that can be trained with smaller datasets, thereby contributing to scientific advancement in this field of study. In this context, after a systematic evaluation, the strategies employed in this work may also contribute to scientific studies related to other AI applications in brain MRI beyond brain neoplasms, such as research on Alzheimer's disease and Parkinson's disease.

THEORETICAL FOUNDATION

2.1 MEDICAL-SCIENTIFIC FOUNDATION

According to the Brazilian National Cancer Institute, in Portuguese, *Instituto Nacional do Câncer (INCA)*, neoplasms of the Central Nervous System (CNS), which include the brain and spinal cord, account for 1.4% to 1.8% of all malignant tumors worldwide. Moreover, 88% of CNS tumors are concentrated in the brain (INCA, 2022). Therefore, studying how to detect this disease early is important to prevent future complications.

2.1.1 Historical Evolution of Brain Neoplasms

The following section presents a brief history of this disease across different centuries: from Antiquity to the twenty-first century (Antiquity, seventeenth century, nineteenth century, twentieth century, and twenty-first century).

Antiquity

In Antiquity, physicians were already aware of certain diseases related to the brain, although brain neoplasms had not been recognized yet (PP; KP, 2015). As no treatments were available for brain neoplasms, the disease manifested through symptoms such as headaches, seizures, and coma, with in the worst cases resulting, in death (CASTILLO, 2014).

Despite the lack of technology during Antiquity, several individuals began studies that have since led to numerous advances in the field of brain neoplasms within the healthcare sector. Notable figures include Celsus, Herophilus, and Galen, as well as Rhazes and Avicenna, Alcmaeon, Praxagoras, and Herophilus (HOLMES, 2021; PP; KP, 2015). Hippocrates (460–370 BC), often regarded as the father of medicine, made significant contributions to the understanding of

modern neurological lesions. In addition, Rhazes and Avicenna (980–1037) conducted studies on brain diseases (HOLMES, 2021).

In Ancient Greece, three important figures in the history of medicine who studied the nervous system were Alcmaeon, Praxagoras, and Herophilus. Alcmaeon introduced significant theories about the brain and nervous system. Praxagoras' studies suggested the existence of neurons. Herophilus distinguished between sensory and motor nerves and provided evidence of the nervous system (PP; KP, 2015). Due to the limited technology available during Antiquity, there were few studies on brain neoplasms, and as a result, this disease was often fatal.

Seventeenth Century

In the seventeenth century, medical knowledge about diseases, including the understanding of human anatomy and physiology including brain neoplasms, remained limited due to the lack of technology. Consequently, medical knowledge was still in its early stages during this century and was also influenced by the cultural and philosophical beliefs of the time.

The diagnosis of brain neoplasms was extremely challenging during this period, mainly due to the absence of imaging technologies such as MRI or CT, which are crucial today for non-invasive brain visualization. As a result, no specific studies on the treatment or diagnosis of brain neoplasms were identified in the seventeenth century.

Nevertheless, in the seventeenth century, Thomas Willis (1621–1675) studied the nervous system and began using the term “neurology.” He discovered that neurological function depended primarily on the brain rather than on its cavities (JR; KAYE, 2002).

In later centuries, through the study of anatomy, the dissection of human brains, and advances in diagnostic technologies, discussed in more detail in the following sections, a deeper understanding of the CNS and the diseases affecting it, including brain neoplasms and their treatments, began to progress significantly.

Nineteenth Century

Unlike in previous centuries, the nineteenth century saw an increase in studies related to brain neoplasms. This occurred, as explained in more detail below, due to advances in areas such as anesthesia, microscope technology, studies of brain anatomy, and brain tumor surgery.

During the nineteenth century, significant developments took place, including the discovery of anesthesia, asepsis, and the localization of brain lesions. The advancement of anesthesia was particularly relevant in surgical practices. These innovations made it possible to perform surgeries to remove brain tumors, which are now common (JR; KAYE, 2002).

In addition, starting in the nineteenth century, significant technological progress was achieved in the development of microscopes. The physicist Ernst Abbé (1840–1905), who collaborated with Carl Zeiss (1816–1888), conducted research on new mathematical formulas and theories that led to improvements in the optical quality of lenses (HOLMES, 2021).

Born in 1835, the Englishman, John Hughlings became one of the greatest researchers contributing to our contemporary understanding of the anatomical localization of brain functions. In 1870, German scientists Gustav Fritsch and Eduard Hitzig conducted studies on the electrical excitability of the cerebral cortex in dogs using galvanic current (KERR *et al.*, 2005).

A scientific article reports that the first removal of a brain tumor was performed in 1879 on a young woman by William Macewen (PREUL, 2005). Furthermore, in 1881, Dr. William Macewen from Glasgow, Scotland, presented a study on the successful removal of a left frontal meningioma in a 14-years-old girl who had survived the procedure performed two years prior. The patient had suffered from seizures that ceased after the operation. This was a major accomplishment given the limited technology available at that time (KERR *et al.*, 2005; MACEWEN, 1965).

In 1884, Rickman Godlee conducted a surgical operation that marked significant progress in studies and techniques related to the neurological field. This progress included advances in imaging techniques for the visualization of brain tumors and a deeper understanding of the biology of these tumors. This was the first time that a tumor was identified solely by neurological methods. Furthermore, in 1887, William W. Keen performed the first meningioma removal in the United States (JR; KAYE, 2002). In 1895, the ability to locate lesions was

further enhanced when Wilhelm Roentgen discovered X-rays (KERR *et al.*, 2005).

In summary, significant developments in the study of brain neoplasms began in the nineteenth century. During this period, major advances were made in anesthesia research, microscope technology, studies of brain anatomy, and brain tumor surgery, among other crucial developments.

Twentieth Century

In the twentieth century, technological advances enabled substantial progress in the study of brain neoplasms. A major reason was the use of medical imaging. In addition, significant progress was made in brain tumor surgery, which will be discussed in more detail below.

During the twentieth century, technological advances, especially the introduction of CT and MRI, resulted in major developments in diagnostic techniques for brain neoplasms. These innovations allowed noninvasive visualization of the brain, enabling early detection of brain diseases and precise identification of tumor locations.

In 1918, Dandy conducted a study and developed the pneumoencephalogram (an early approach used to examine the brain through imaging). This represented a significant advancement in brain research, contributing to studies related to the radiological localization of lesions in the CNS (KERR *et al.*, 2005).

Furthermore, the first removal of a brain tumor using electrocauterization (a medical device that eliminates skin lesions and imperfections through electric discharge) was performed by Harvey Cushing, considered the father of modern neurosurgery, in 1926. He played a crucial role in advancing brain tumor surgery. Among his numerous contributions, he introduced anesthetic methods and electrosurgical devices (KOMORI, 2017).

Thus, the twentieth century marked the beginning of more comprehensive studies on brain neoplasms, mainly due to technological innovations. These advances facilitated the development of imaging techniques for detecting and accurately locating tumors through medical analyses, along with remarkable progress in brain tumor surgery, among other factors.

Twenty-first Century

In the present century, technological advances in medical imaging have simplified the diagnosis and localization of brain neoplasms. In this context, the contributions of artificial intelligence should be emphasized.

The recent historical evolution in the twenty-first century has been characterized by the use of CT and MRI. These techniques have enabled physicians to visualize brain structures and determine the presence, location, and features of tumors (LOUIS *et al.*, 2007).

An important aspect is the current trend in which such identifications are performed using machine learning techniques. In this context, AI can assist in the accurate identification of tumoral regions, predict tumor behavior, and select the most appropriate treatments.

Thus, while brain neoplasms continue to have serious consequences, in the twenty-first century, significant progress is occurring in their detection and treatment. This includes the use of machine learning for automatic classification of brain neoplasms using MRI images, with recent emphasis on deep learning.

Moreover, the advent of technology has provided several advantages, for instance, improved diagnostic techniques, reducing the surgical risks associated with tumor removal (PREUL, 2005). Furthermore, due to current technological innovations, research in robotics, biotechnology, and nanomedicine is substantially transforming the field of brain tumor surgery (HOLMES, 2021).

Consequently, the technological advances of the twentieth century, i.e., the CT and MRI imaging, continue to be highly relevant for studies and procedures related to brain neoplasms in the twenty-first century. However, with the emergence of AI, machine learning, and deep learning techniques, these tools have become automated aids to assist physicians in the diagnosis of brain neoplasms.

2.1.2 Global Epidemiology of Central Nervous System Neoplasms

Cancer is a type of malignant tumor (NIH, 2021). According to the International Agency for Research on Cancer, 19,292,789 people, of all ages and genders, suffered from cancer worldwide

in 2020 (International Agency for Research on Cancer, 2023).

In 2020, the International Agency for Research on Cancer recorded 207,228 deaths caused by brain neoplasms affecting the CNS, including all genders and ages from 0 to 74 years. This statistic exclude non-melanoma squamous cell carcinoma, which are thin flat cells that form the outermost layer of the skin, the epidermis (International Agency for Research on Cancer, 2023). On the other hand, Melanoma, originates in melanocytes (cells that produce melanin) and is more aggressive.

Figure 2.1 illustrates mortality numbers related to CNS tumors in Brazil. In 2020, 9,355 deaths were recorded, with 4,787 in men and 4,567 in women. In 2022, the number of deaths increased to 11,490, with 6,110 in men and 5,380 in women (INCA, 2022). The graph highlights a higher number of deaths related to CNS tumors among men, with a significant increase in the gender gap in 2022.

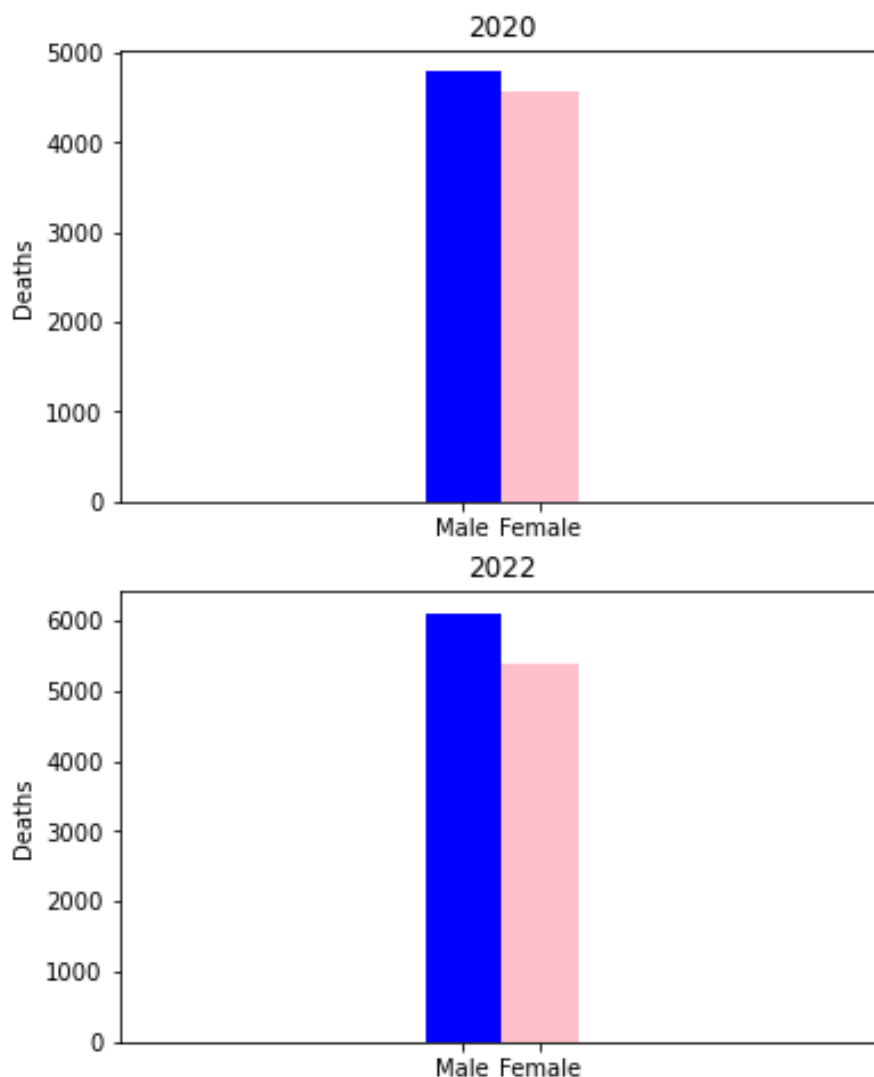


Figure 2.1: Numbers of deaths related to Central Nervous System (CNS) tumors in Brazil in 2020 and 2022.

Source: Data from (INCA, 2022).

2.1.3 Types of Brain Neoplasms

According to the INCA, some causes of neoplasms in the CNS include exposure to radiation, arsenic, lead, mercury, as well as occupational hazards in various industries such as petrochemical, rubber, plastic, printing, paper, textile, and pesticide manufacturing. Other risk factors include employment related to refineries, nuclear power plants, automotive production and repair, electrical and telephone services, and agriculture (INCA, 2022). Notably, ionizing radiation is the main risk factor for specific types of nervous system neoplasms, particularly

those classified as glial and meningeal neoplasms (DEANGELIS, 2001).

Brain neoplasms cause two different types of neurological symptoms: focal and generalized. The former occurs due to the intracranial location of the tumor, while the latter result from increased intracranial pressure. This may lead to headaches and, in more severe cases, nausea, vomiting, and other symptoms (DEANGELIS, 2001).

As mentioned earlier, a specific type of nervous system neoplasm is the glial neoplasm. These can be categorized as *astrocytic* or *oligodendroglial*, and both types can be either high-grade or low-grade (DEANGELIS, 2001).

Astrocytic neoplasms usually occur in adults between 30 and 40 years of age. The first symptom of this condition is often seizures, and in cases where surgery is not required, radiotherapy is a common treatment option (DEANGELIS, 2001).

The *oligodendroglial* neoplasm is generally of the low-grade type. This type is associated with vascularization that can lead to hemorrhages. The diagnosis and treatment of *oligodendroglial* neoplasms are similar to those of low-grade astrocytomas. Patients with *oligodendroglial* neoplasms have a considerably longer average survival rate—approximately 10 years—compared to the average survival rate of 5 years for low-grade astrocytomas (DEANGELIS, 2001).

This study focuses on three different types of brain neoplasms: meningioma, glioma, and pituitary adenoma. Figure 2.2 shows MRI examples of these three different types of brain neoplasms, respectively, with the region of neoplasia identified.




Figure 2.2: Examples of brain neoplasm images: Left - Meningioma, Middle - Glioma, Right - Pituitary adenoma

Source: Images obtained from the database: (CHENG, 2017).

Meningioma consists of a type of neoplasm located in the meninges and arises from cells known as *meningothelial* cells (OSBORN, 2014). It is the most common benign brain neoplasm, accounting for about 15% of all intracranial neoplasms in adults. Its incidence occurs mainly in adults, with cases in individuals under 30 years of age being rare (RUNGE *et al.*, 2015). Furthermore, although meningiomas are classified as brain neoplasms, they are not located within the brain itself, but rather originate in the outer membrane of the brain (DEANGELIS, 2001).

Glioma, which develops from glial cells, is considered one of the most heterogeneous types of brain neoplasms (OSBORN, 2014). This type of neoplasm can present different growth patterns and symptoms, which require distinct treatment responses, making its identification and clinical follow-up a challenge.

Pituitary adenomas are classified according to size. They are called *microadenomas* when smaller than or equal to 10 mm, and *macroadenomas* when larger than or equal to 11 mm. In addition, pituitary adenomas are located in the sellar and suprasellar regions of the brain. The sellar region is one of the most complex areas of the brain (OSBORN, 2014).

2.1.4 Medical Imaging Acquisition Modalities

Methods for detecting brain neoplasms can be either invasive or noninvasive. Invasive detection involves biopsy, while noninvasive methods include CT and MRI (TANDEL *et al.*, 2019).

CT consists of the emission of X-rays through ionizing radiation and can detect bone structures, calcifications, and hemorrhages. Some multi-detector CT scanners provide reduced examination time (LEITE *et al.*, 2008).

MRI is composed of a main magnet and radiofrequency (RF) transmitter and receiver coils, which generate energy emission and enable signal reception. The MRI signal is encoded and digitized by an analog-to-digital converter and then stored on a computer. Mathematical processing of the signal is performed using the *Fourier* transform, allowing image reconstruction (LEITE *et al.*, 2008).

MRI is the main diagnostic test for brain neoplasms (DEANGELIS, 2001), making it one of the most important noninvasive imaging techniques used to capture detailed images of the brain and spinal cord, as well as other organs and structures, such as bones, muscles, soft tissues, and tumors.

To obtain MRI images, the patient must remain inside the scanner for approximately thirty minutes to one hour. The images produced by MRI allow early identification of specific abnormalities in defined body regions and assist in medical diagnosis.

MRI produces images in several planes, including sagittal, axial, and coronal.

The sagittal plane divides the body into right and left parts and displays longitudinal structures.

The axial plane is perpendicular to the longitudinal axis of the body, showing cross-sectional structures.

The coronal plane divides the body into anterior and posterior parts, showing structures in a frontal section.

Examples of these MRI slices are shown in Figure 2.3, with the sagittal plane on the left,

the axial plane in the center, and the coronal plane on the right.




Figure 2.3: Examples of the three MRI slices from different patients (left: sagittal, middle: axial, right: coronal).

Source: Images obtained from the database: (CHENG, 2017).

In addition to conventional MRI, there is a type of scan called Functional Magnetic Resonance Imaging (fMRI), in which the patient performs specific tasks while brain images are acquired. Some disadvantages of this technique include acoustic noise, motion artifacts, and a claustrophobic environment. Nevertheless, it presents several advantages, such as the absence of ionizing radiation, no dependence on contrast agents, and high spatial and temporal resolution (LEITE *et al.*, 2008).

Besides these two main modalities—CT and MRI—there is also radiography. However, cranial radiography is not commonly used today, because in most cases, the clinical investigation focuses on the brain rather than the skull (OSBORN, 2014).

One of the various MRI applications is a protocol known as Digital Imaging and Communications in Medicine (DICOM). This is an international standard established in 1983 to unify the storage and communication of medical images such as X-rays, MRI, and CT scans. It defines a standardized electronic format that includes both the image and its metadata (patient information, examination data, and equipment details) (NEMA, 2023; UCSF - University of California, San Francisco, 2024).

The main functions and benefits of the DICOM protocol include: standardization of medical image formats; facilitation of data exchange between different systems and manufacturers; access and analysis of images through compatible software; improvement of workflow in hospitals and clinics; and consequently, enhancement of medical research integration (NEMA, 2023; DICOM Standard, 2023; PIZER; ACKERMAN, 1996).

In summary, CT and MRI are the two main techniques for medical image acquisition. In this work, the focus is on MRI, as numerous studies have analyzed this imaging modality for the development of automated diagnostic systems using AI, thereby promoting the investigation of tools to support medical diagnosis.

2.2 ARTIFICIAL INTELLIGENCE

Machine learning consists of the automated detection of patterns (SHALEV-SHWARTZ; BEN-DAVID, 2014). This subfield of AI (ALPAYDIN, 2014) is a scientific discipline that, among various applications, includes image classification.

According to the Encyclopædia Britannic, machine learning is a branch of AI that involves automatic learning performed by computers (HOSCH, 2022). The machine learning process includes algorithms for feature extraction and image classification. Feature extraction and classification can be performed separately using various techniques, but they can also be automated through deep learning algorithms.

The two main types of learning problems are classification and regression. Classification deals with small, discrete values (WERNICK *et al.*, 2010). It involves an input feature vector that may consist of discrete or continuous values, and the output is represented by discrete values corresponding to the classes (DOMINGOS, 2012). An example of a classification task is the objective of this work — the identification of brain neoplasms in MRI images. In contrast, regression deals with continuous output variables and can be used, for instance, in diagnostic assessments to estimate disease severity (WERNICK *et al.*, 2010).

Another important concept is data mining, which includes machine learning techniques to analyze large databases. Some examples of data mining applications include finance, fraud detection, stock market analysis, manufacturing, medicine, telecommunications, and science (ALPAYDIN, 2014).

The machine learning development process involves pattern recognition. This is similar to what occurs in the human brain when features such as eye color, face shape, or size are unconsciously identified to recognize a person (ALPAYDIN, 2014). Therefore, the first step in this process is to extract features that are relevant for a classification system (DOMINGOS,

2012).

2.2.1 Historical Factors in the Evolution of Artificial Intelligence

In 1943, McCulloch and Pitts conducted the first study that initiated what is now known as Artificial Intelligence (AI) (MCCULLOCH; PITTS, 1943). In 1950, two university students, Marvin Minsky and Dean Edmonds, at Harvard, developed the first neural network computer (RUSSELL; NORVIG, 2010).

AI was formally established in 1956 (RUSSELL; NORVIG, 2010). About the same time, John McCarthy introduced this term at a conference and defined it as "the science and engineering of making intelligent machines" (LUGER, 2004).

The development of AI led to several subfields, including Machine Learning, which in turn led to the emergence of Deep Learning. Therefore, Machine Learning and Deep Learning are subareas of Artificial Intelligence.

Classification

After feature extraction, these features are used to train classification systems. This process finds applications in various fields, such as business intelligence, email spam detection, and fraud detection. Another significant application is medical imaging, which is the focus of this study. An example of this is the development of an algorithm that determines whether an individual's image, as seen in medical scans, corresponds to a healthy or diseased state (WERNICK *et al.*, 2010).

The three main types of classification in machine learning are supervised, unsupervised, and reinforcement learning. In supervised learning — the most common approach in the literature — labels (which represent the classes) are provided to the system during the training process. Whereas in unsupervised learning, this label information is not given; instead, the system learns through mathematical computations during the classification phase. In reinforcement learning, the system learns its optimal actions.

For image classification in machine learning using supervised learning, several methods and

algorithms can be employed. The most employed algorithm include Support Vector Machines, K-Nearest Neighbors, ensemble methods, Logistic Regression, Naive Bayes, and Decision Trees.

Deep learning techniques have gained significant popularity for image classification tasks due to their remarkable results. These techniques allow feature extraction and classification to be performed automatically. The choice of a specific classification technique often depends on its performance results and the computational cost associated with it.

Training and testing are the two main stages of the classification process. In the training stage, the system uses features as input and, through mathematical and statistical computations, builds an optimization model that distinguishes between different classes within the dataset. After training, statistical metrics are employed to test the results generated by the classifier using a dataset that must not be used during the training process (ALPAYDIN, 2014).

Classification involves mapping the input data of a system to output classes, usually during the testing phase of learning. The goal is to find a function that effectively separates the data into distinct classes based on their features (HASTIE *et al.*, 2009). Mathematical metrics are obtained to support this analysis.

Machine Learning

The term "machine learning" was first used by Arthur Samuel in 1959 (GEROVITCH, 2015; LINDSAY, 1964). He developed a program to play checkers that improved its performance through experience (SAMUEL, 1959).

In the twenty-first century, with technological advances, the use of machine learning has achieved substantial improvements. These advances have revolutionized machine learning, particularly in areas such as speech recognition, computer vision, medicine, and others. Notably, deep learning techniques have improved significantly in recent years.

Deep Learning

Deep Learning (DL) is a subfield of Machine Learning. The popularity of DL has changed, with periods of greater and lesser adoption. The term "deep learning" was initially used within

the machine learning community by Rina Dechter in 1986 (DECHTER, 1986).

In the field of artificial neural networks, DL was first used by Igor Aizenberg and collaborators in 2000 (AIZENBERG *et al.*, 2000). Therefore, the extensive use of DL in the industry began in the early 2000s.

DL has been employed due to the increase in the amount of available data and improvements in hardware and software computing infrastructure. As a result, learning techniques have been applied over the years to increasingly complex tasks, providing better results (GOODFELLOW *et al.*, 2016).

Deep convolutional networks have been applied to image, video, speech, and audio processing. On the other hand, neural networks have also been employed in tasks such as text and speech processing (LECUN *et al.*, 2015).

Furthermore, deep learning classifiers can automate both feature extraction and classification processes. Examples of deep learning approaches include Convolutional Neural Networks (CNN), Recurrent Neural Networks (RNN), Generative Adversarial Networks (GAN), Reinforcement Learning (RL), Transformer Neural Networks, Deep Neural Networks (DNN), Deep Belief Networks (DBN), Deep Autoencoders, Deep Boltzmann Machines (DBM), and Deep Convolutional Extreme Learning Machines (DC-ELM) (AGGARWAL, 2018; NIA *et al.*, 2023).

Several scientific studies have employed DL due to its ability to perform automatic feature extraction, as well as its capacity to improve training accuracy, despite its higher computational cost compared to other strategies (SOMASUNDARAM; GOBINATH, 2019).

2.2.2 Examples of Classifiers

Support Vector Machines

Support Vector Machines (SVM) consist of a supervised learning model that requires labeled data as input to the classification system and is primarily used for classification and regression tasks.

The goal of an SVM is to find an optimal hyperplane that separates the classes with the maximum possible margin. This technique identifies support vectors, which are the points

closest to the hyperplane representing the decision boundary in a multidimensional space.

This approach performs well in high-dimensional spaces and is effective even when the number of samples is small. In cases that are not linearly separable, the data are mapped to a higher-dimensional, linearly separable, and often infinite-dimensional space using a mapping function ϕ associated with the kernel of the system. The most commonly used kernel function is the Radial Basis Function (RBF).

Artificial Neural Network

A biological neuron is composed of dendrites, which receive signals from other neurons; a cell body, which processes the signals; and an axon, which transmits the signal to other neurons.

An Artificial Neural Network (ANN) functions similarly to a biological neuron, in which each artificial neuron receives inputs (numerical values), applies weights, sums them, and passes the result through an activation function, after which the signal is transmitted to the next neurons in the network. Thus, artificial neural networks learn by adjusting the connections (weights) between neurons to perform tasks such as classification, regression, or pattern recognition.

A simplified neural network, called a perceptron, consists of a single layer (input) with multiple neurons, each having its own weights, and has no hidden layers. The perceptron algorithm learns the weights of the input signals to draw a linear decision boundary.

Multilayer Perceptron

Multilayer Perceptrons (MLPs) consist of one of the most basic architectures of neural networks. They are composed of an input layer (which receives the data, where each input neuron represents a feature) and one or more hidden layers (which perform the processing).

For each neuron in a hidden layer or in the output layer, the weighted sum of its inputs is calculated. Each input is multiplied by its corresponding weight, then these products are summed, and the bias is added. Additionally, the network includes an output layer, which generates the result, and each neuron in a layer is connected to all neurons in the fully connected network. MLP also employs nonlinear activation functions such as ReLU, sigmoid, and tanh.

Convolutional Neural Networks

Convolutional Neural Networks (CNNs) are a specialized architecture designed for data with spatial structure, such as images, using mathematical computations. CNNs automatically learn the best filters to extract the most relevant features, unlike previous networks that classify data based on manually extracted features. The goal of training a CNN is to determine the weights and biases of the convolutional volumes. Furthermore, CNNs are extremely efficient in recognizing patterns in images, videos, audio, and other types of data.

The main layers used in CNNs and their respective explanations include:

1. **Convolutional layers:** Extract features from images;
2. **Global Average Pooling:** Summarizes each activation map into a single average value, reducing complexity and preventing overfitting;
3. **Batch Normalization:** Normalizes the activations from the previous layer, helping to accelerate training and stabilize learning;
4. **Dropout:** Randomly deactivates a fraction of neurons during training, also helping to reduce overfitting;
5. **MaxPooling:** Reduces the spatial dimension of the images by selecting the highest values within specific regions, preserving the most relevant information;
6. **Flatten:** Transforms multidimensional outputs into a one-dimensional vector to be processed by dense layers; and
7. **Dense:** Performs the final learning through connections between neurons.

2.2.3 Some Applications of Machine Learning in the Literature

Machine learning finds wide applications in studies related to images, including various tasks, such as object recognition, facial detection, image segmentation, and medical image classification.

An essential application in this domain involves the processing of medical images, including CT and MRI scans. This application is directly related to the present work, in which machine learning algorithms are employed to detect and identify brain neoplasms in medical images.

For this purpose, the main AI techniques employed are machine learning and DL, as mentioned in the literature (NIA *et al.*, 2023). AI has been applied to diagnosis and classify malignant diseases that affect the CNS (LUO *et al.*, 2023). India, the United States, and China are the most productive countries in terms of scientific publications in this field, according to the literature (HOSSAIN *et al.*, 2023).

The literature includes a wide range of machine learning applications across different fields. These include image reconstruction (WANG *et al.*, 2021); studies related to pesticides (DAI *et al.*, 2023); COVID-19 identification using X-ray images (KHAN, 2021); detection of malnutrition and prediction of body mass index (BMI) (CHITTATHURU *et al.*, 2021); and, particularly, classification of medical images using MRI to identify diseases (SOLANKI *et al.*, 2023), which is the main focus of this work.

Deep learning has become predominant in the field of machine learning, especially in applications such as deep tomographic image reconstruction (WANG *et al.*, 2021) and studies involving brain imaging (SCHULZ *et al.*, 2020; KHAN *et al.*, 2022; NAYAK *et al.*, 2022; TANDEL *et al.*, 2019).

In summary, Machine Learning has transformed the way images are processed and interpreted, with applications ranging from object recognition to diagnostic medicine, providing significant technological advances for the future.

2.2.4 Generative Adversarial Network

Generative Adversarial Networks (GANs) represent a data augmentation approach widely used in the state of the art to improve classifier performance. A GAN is composed of two main components: the generator, which creates images aimed at resembling real data, and the discriminator, which evaluates whether each generated sample is real or fake. The generator attempts to confuse the discriminator, while the discriminator attempts to correctly identify false samples. Thus, throughout the learning process, the generator gradually learns to produce

increasingly realistic data.

GANs have been frequently employed in scientific studies involving MRI (MRI), including research on different types of brain neoplasms. In other words, the generation and classification of brain MRI images using GANs combined with deep learning techniques have been widely discussed in the literature (ALRASHEDY *et al.*, 2022).

A GAN can be particularly useful for augmenting training datasets when they are insufficient for effective learning (GE *et al.*, 2020). Since medical datasets with relatively large sample sizes are rare, techniques such as GANs are often applied (AHMAD *et al.*, 2022).

Several studies have evaluated GAN models incorporating noise (HAN *et al.*, 2019), and others have focused on improving system performance through the use of GANs (HAN *et al.*, 2019). Furthermore, GANs can be used for tumor segmentation in brain MRI images (SILLE *et al.*, 2023; HAMGHALAM; SIMPSON, 2024; E.; SARULADHA, 2020) and in combination with super-resolution techniques to enhance MRI image quality (MOHSEN *et al.*, 2023; ZHOU *et al.*, 2022).

GAN applications can be employed across different types of imaging. For instance, one study used a GAN to generate images of healthy brains, compensating for the insufficient number of samples in this class compared to others in the dataset (ALRUMIAH *et al.*, 2023).

Another study applied a GAN to augment the dataset of brain neoplasm images (SAHOO *et al.*, 2023). Additionally, one study focused specifically on meningioma MRI images using GAN-based generation (DEEPAK; AMEER, 2020).

In summary, GANs are particularly useful for increasing the number of MRI images when the training dataset is too small to support deep learning models capable of achieving expressive results, according to the literature (GE *et al.*, 2020).

Some of the main layers commonly used in CNN-based generator and discriminator networks, which have not yet been described in this work, are listed below:

1. **LeakyReLU:** introduces a small slope for negative outputs of the ReLU activation function;
2. **Reshape:** reorganizes data, preparing it for subsequent convolutional layers;

3. **Conv2DTranspose:** increases the spatial resolution of images, gradually reconstructing details from lower-dimensional representations;
4. **Final Conv2DTranspose layer:** produces the final output image with the desired number of channels (in this case, 3 for Red, Green and Blue (RGB)), transforming the feature maps into a realistic image.

MATERIALS AND METHODS

To develop this research, different methods were used to classify brain tumor images (meningioma, glioma, and pituitary adenomas) within a single dataset, with and without data augmentation. Initially, this type of analysis was applied and compared across the three anatomical slices (axial, coronal, and sagittal). As the axial produced the best results, later analysis focused on that anatomical slice. Traditional data augmentation techniques were applied using a CNN developed from a custom architecture and from pre-trained networks (Strategy 1). Subsequently, classification techniques were applied to features extracted by CNN (Strategy 2). Finally, Transfer Learning was employed (Strategy 3). In addition, some of these training models were performed using images generated by a GAN.

3.1 DATABASE

3.1.1 Figshare - 3 Classes

Table 3.1 presents the characteristics of the database (CHENG, 2017) as referenced in (CHENG *et al.*, 2015) and (CHENG *et al.*, 2016). The patient data were classified by three radiologists. This table states that the number of patients was 233. The data collection took place at Nanfang Hospital, Guangzhou, China, and the General Hospital of Tianjin Medical University, China. These data were obtained between September 2005 and October 2010. The image pixels are 512 by 512, and the slice size is 0.49×0.49 mm². The total number of images is 3064, with 708 meningioma, 1426 glioma, and 930 pituitary adenoma images; therefore, several images correspond to each patient. Data acquisition was approved by the ethics committees of Nanfang Hospital and the General Hospital of Tianjin Medical University. The MRI images were acquired in axial, sagittal, and coronal slices, meaning that the database contains images from different slices of the same individual (no information was found regarding the type or specific region of each slice) (CHENG, 2017). Furthermore, the magnetic resonance images in

this database were acquired with T1-weighted contrast (CHENG *et al.*, 2015).

Table 3.1: Characteristics of the database (CHENG, 2017) as referenced in (CHENG *et al.*, 2015).

Characteristics	
Number of patients	233
Data collection sites	Nanfang Hospital, Guangzhou, China, and General Hospital, Tianjin Medical University, China
Image resolution	512×512
Slice size	$0.49 \times 0.49 \text{ mm}^2$
Number of images	3064 (708: meningioma, 1426: glioma, and 930: pituitary adenoma)
Ethics committee	Ethics Committees of Nanfang Hospital and General Hospital, Tianjin Medical University
Slices types	Axial, sagittal, and coronal

Limitations

This research presents some limitations due to the chosen dataset. No information is available about the patients from whom the images and data were obtained. In addition, this database does not include a control group composed of healthy individuals without brain neoplasms, which could be useful for the development of a diagnostic system.

Nevertheless, this dataset was selected because of the significant number of images, its relevance in the existing literature, and the fact that it was approved by an ethics committee.

Preprocessing

To use these images, Python codes were developed using the Spyder platform and Colab. The main automatic MRI classification algorithm developed in this study was duly registered with the *Instituto Nacional da Propriedade Industrial (INPI)* (FARIA *et al.*, 2025). A notebook computer with the following specifications was used: 64-bit Windows 10 operating system, NVIDIA GeForce graphics card with 2 GB of memory, Intel Core i5 processor, 8 GB of RAM, and approximately 1 TB of storage.

The data for each slice (axial, sagittal, and coronal) were manually separated, and each image was resized to 256×256 using the `cv2.resize` function from the OpenCV library in

Python (OPENCV-TEAM, 2024). This was done to reduce computational cost, since even with smaller dimensions, the images produced relevant results, according to the literature.

The images were normalized based on their original intensity values. Then, the values were rescaled to the range $[0, 255]$ (digital images with 8 bits per channel), saved in the `.jpg` format, and converted to the `uint8` format (8-bit unsigned integer).

To organize the images, each file name followed the model: `x1_x2_x3`, in which the first number (`x1`) indicates the image order number, the second number (`x2`) is the patient ID number, and the third (`x3`) indicates the class (1 for meningioma, 2 for glioma, and 3 for pituitary adenoma).

Each pixel was represented in an 8-bit grayscale format, with integer values ranging from 0 (black) to 255 (white). The images were resized in each strategy to adjust their dimensions to the requirements of the model and optimize classification performance. In addition to analyzing all slices together, each slice was analyzed separately, and the axial slice was selected for this study since it produced the best results. No information was found regarding the specific characteristics of the slices available in the database.

The data were tested to ensure that there was no data leakage, meaning images from the same individual did not appear in different groups. For this purpose, an algorithm was developed to extract the ID numbers from the image names. Then, using these values, a Python function checked whether there was any intersection between the test and training groups. No intersection was found, which confirmed that there was no data leakage.

Furthermore, predefining the training and validation data caused *overfitting* in the obtained results. Therefore, the training and validation folders were merged into one, allowing the system to automatically split the data into training (80%) and validation (20%) during the execution of the codes related to the axial slice analyses.

3.2 CNN USING DATA AUGMENTATION – STRATEGY 1

In this strategy, data normalization (scaling from 0 to 1) was applied. Approximately 80% of the data were used for training (20% of which were used for validation) and 20% for testing. The number of epochs was set to 100. At this stage, k-fold cross-validation was not used because

the number of images in the axial slice group is relatively small for this type of application. The convolutional network layers were defined after several tests that verified the layers that achieved the best results. The batch size was set to 32 for the axial case and 100 for the full dataset, adapting to the number of images in each case; the RGB color scale was also defined.

At this stage, model training follows an automatic resumption logic from the last saved checkpoint. Initially, the model is loaded from a previously saved file or initialized if none exists. During training, the progress of the model is saved, and the accumulated history is updated with training and validation accuracy and loss. Training is performed using data generators for a defined number of epochs and can be resumed from the last completed epoch, avoiding a full restart in case of interruptions.

To increase the variability of the training set and reduce the risk of *overfitting*, two types of data augmentation were applied: horizontal flip and addition of Gaussian noise. The horizontal flip consists of reversing the image pixels along the horizontal axis, generating a new sample that preserves the structural features of the lesion but changes its spatial orientation. Gaussian noise was added to simulate acquisition variations and small imperfections inherent to real MRI scans. For this, random noise with a normal distribution of zero mean and standard deviation equal to 40 was generated, added to the original pixel values, and subsequently limited to the range $[0, 255]$ to ensure the integrity of the intensity levels. Furthermore, in the training, the size of the training matrix was doubled during the data augmentation step to further expand the dataset.

The convolutional network layers were defined after several tests, after verifying that the chosen layers achieved better results and were also consistent with those reported in the literature. The following sections present the layers of the networks defined for each stage of this strategy.

3.2.1 All Three Slices

At this stage, the convolutional layers were obtained as shown in Figure 3.1, which illustrates the custom CNN model using images from all three slices. In this case, the network is composed of three sequences of convolutional, maxpooling, and dropout layers, followed by one flatten

layer, one dense layer, another dropout, and a final dense layer.




Figure 3.1: Block diagram of the convolutional layers of the CNN network using images from all three slices. This network has three sequences of convolutional, maxpooling, and dropout layers, followed by one flatten layer, one dense layer, another dropout, and a final dense layer.

Furthermore, using the pretrained CNN model (VGG16), the convolutional layers were obtained as shown in Figure 3.2. In this case, the network consists of a sequence of convolutional, batch normalization, maxpooling, global average pooling, dropout, and dense layers.

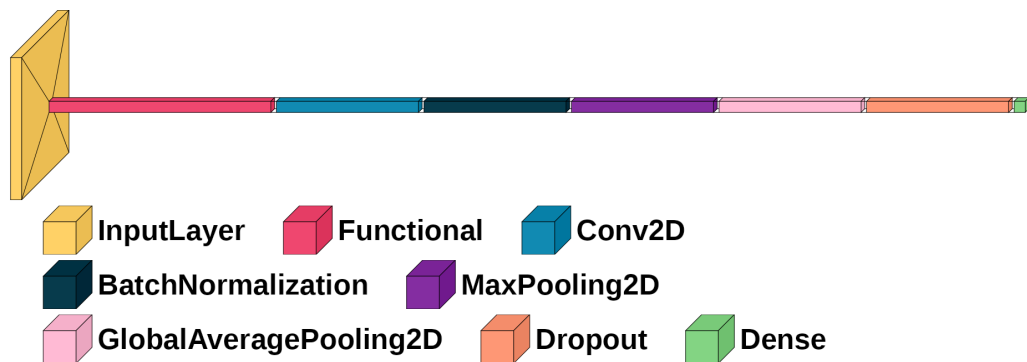


Figure 3.2: Block diagram of the convolutional layer stages of the pretrained CNN network (VGG16) using images from the three different slices. This network consists of a sequence of convolutional, batch normalization, maxpooling, global average pooling, dropout, and dense layers.

3.2.2 Axial Slice Only

At this stage, the convolutional layers of the custom network were designed according to the diagram shown in Figure 3.3, which corresponds to the CNN model using only axial slices, as

these achieved the best results. In this case, the network contains three sequences of convolutional and maxpooling layers, followed by one global average pooling, one dense, one dropout, and a final dense layer.

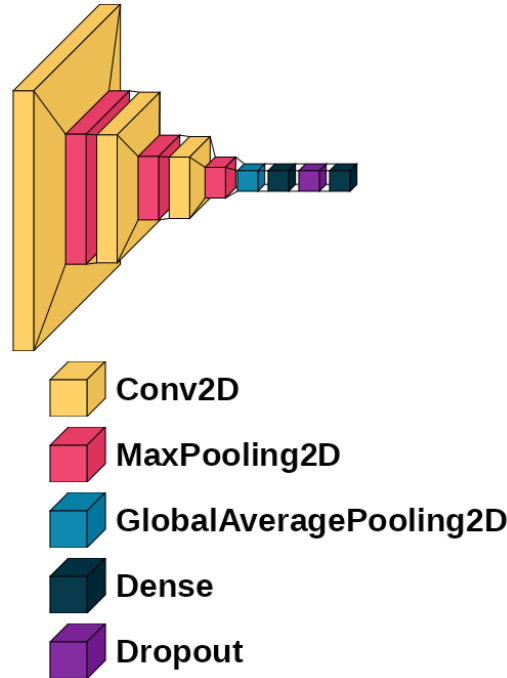


Figure 3.3: Block diagram of the convolutional layers in the CNN model using only axial slices. This network is composed of three sequences of convolutional and maxpooling layers, followed by one global average pooling, one dense, one dropout, and a final dense layer.

Furthermore, using the pretrained CNN model (VGG16), the convolutional layers were obtained as shown in Figure 3.4. In this case, the network has a sequence of global average, dropout, and dense layers.

3.3 FEATURE EXTRACTION USING CONVOLUTIONAL NEURAL NETWORKS - STRATEGY 2

In the second stage, CNNs were used for feature extraction, employing the following models: DenseNet121, MobileNet, EfficientNetV2 B0, Inception V3, and Xception. These approaches produced the quantities of extracted features indicated in Table 3.2.

In general, the layers of these networks extract basic visual patterns, such as edges and simple textures. Furthermore, they capture more complex shapes and textures, and extract anatomical patterns and intensity variations relevant to distinguishing healthy tissue from re-




Figure 3.4: Block diagram of the convolutional layers in the pretrained CNN (VGG16) model using only axial slices. This network is composed of a sequence of global average, dropout, and dense layers.

Table 3.2: Number of features (divided into training and testing sets) extracted by each deep learning architecture.

Architecture	Number of Features
DenseNet121	1024
MobileNet	1024
EfficientNetV2 B0	1280
Inception V3	2048
Xception	2048

gions with neoplasms. Thus, the final feature vectors (ranging from 1024 to 2048 dimensions) act as a compact representation of the MRI images, allowing the classifiers to distinguish between different types of brain tumors. Then, for each model, the dimensionality of the extracted features was reduced to 256 features using Principal Component Analysis (PCA). This process was applied to both training and testing data for each model, making the data even more compact.

Subsequently, these features were used in the classifiers presented in Table 3.3, employing only axial slices and three classes (meningioma, glioma, and pituitary adenoma). At this stage, 10 iterations were performed using the k-fold method to avoid overfitting, adapted only to the training data, while the testing data were separated and remained fixed. Moreover, in this stage, three channels were used, meaning that the RGB scale was defined.

Table 3.3: Classifiers and their parameters used in this work under Strategy 2. All from the scikit-learn package (PEDREGOSA *et al.*, 2011).

Classifiers	
C0	Logistic Regression: LogisticRegression(penalty='none', solver='newton-cg')
C1	K Nearest Neighbors (KNN): KNeighborsClassifier()
C2	Decision Tree Classifier: DecisionTreeClassifier()
C3	SVM: svm.SVC(kernel="rbf")
C4	Stochastic Gradient Descent: SGDClassifier(loss="hinge", penalty="l2", max_iter=5)
C5	Random Forest: RandomForestClassifier(max_depth=2, random_state=0)
C6	Gaussian Naive Bayes: GaussianNB()
C7	Quadratic Discriminant Analysis (QDA): QuadraticDiscriminantAnalysis()
C8	MLP: MLPClassifier(alpha=1, max_iter=1000)
C9	Bagging Classifier: base_classifier=DecisionTreeClassifier(random_state=42) BaggingClassifier(base_estimator=base_classifier, n_estimators=10, random_state=42)
C10	Extra Trees Classifier: ExtraTreesClassifier(n_estimators=200, random_state=42)
C11	Linear Discriminant Analysis (LDA): LinearDiscriminantAnalysis()

3.4 TRANSFER LEARNING - STRATEGY 3

In addition, pre-trained network techniques, known as Transfer Learning, were employed. These consist of machine learning classification strategies that use the knowledge acquired by a pretrained model on a given task to improve performance on a different application. Furthermore, a batch size of 32, no data augmentation, and three channels (RGB scale) were defined, as these parameters yielded the best results obtained.

At this stage, the convolutional layers were designed as shown in Figure 3.5, corresponding to the Transfer Learning model. In this case, the network is composed of a global average pooling layer, two sequences of dense, batch normalization, and dropout layers, followed by a final dense layer.



Figure 3.5: Block diagram of the convolutional layers in the CNN Transfer Learning model using only axial slices. This network consists of a global average pooling layer, two sequences of dense, batch normalization, and dropout layers, followed by a final dense layer.

Table 3.4 provides the number of images in each class for the test, training, and validation sets for the axial, sagittal, and coronal slice groups used to compare the use of Transfer Learning

(Strategy 3). A total of 80% of the data was reserved for training (20% of the training images were set used for validation) and 20% for testing. For this split, the image filenames, particularly the ID number, were used as references. The image size was set to 256x256 pixels and the training ran for 500 epochs.

Table 3.4: Number of test images per class: class 1 represents meningioma tumors, class 2 glioma, and class 3 pituitary adenoma. Approximately 80% were used for training (20% of which were separated for validation) and 20% for testing for each slice (axial, sagittal, and coronal). Strategy 3.

	Test	Train	Validation
Axial:			
Class 1 (meningioma)	37	139	31
Class 2 (glioma)	99	314	83
Class 3 (pituitary adenoma)	49	194	98
Sagittal:			
Class 1 (meningioma)	61	159	48
Class 2 (glioma)	65	213	44
Class 3 (pituitary adenoma)	83	282	72
Coronal:			
Class 1 (meningioma)	53	147	32
Class 2 (glioma)	103	296	80
Class 3 (pituitary adenoma)	61	201	50

Using the axial slice, several models were selected, including DenseNet121, MobileNet, EfficientNetV2 B0, Inception V3, and Xception, as these models are commonly used in the literature. Table 3.5 presents the number of images in each class for the test, training, and validation sets, respectively, for the axial slice group (which achieved the best results) used in Transfer Learning (Strategy 3). The separating training and validation data caused overfitting in the results. Therefore, the training and validation data folders were merged in the Transfer Learning algorithms. For the axial group, 80% of data were reserved for training, 10% of the training images were separated for validation, and 20% of data were used for testing. The separation was again based on image filenames, particularly the ID number. Moreover, 140 epochs were used, with an image size of 224x224 pixels.

Table 3.5: Number of test images per class: class 1 represents meningioma tumors, class 2 glioma, and class 3 pituitary adenoma. Approximately 80% were used for training (10% of which were separated for validation) and 20% for testing. Strategy 3.

	Test	Train	Validation
Axial:			
Class 1 (meningioma)	37	155	15
Class 2 (glioma)	99	354	43
Class 3 (pituitary adenoma)	49	219	23

3.5 GENERATIVE ADVERSARIAL NETWORK

For this stage, the following parameters that achieved the best results were used: 3000 epochs, batch size of 32, 3 channels, noise dimension of 100, and image size of 256×256 , with the following layers for the generator and discriminator, respectively.

The convolutional layers of the GAN generator were designed as shown in Figure 3.6. The generator model consists of Dense, BatchNormalization, LeakyReLU, Reshape, and multiple Conv2DTranspose layers, ending with a final Conv2DTranspose layer.



Figure 3.6: Block diagram of the convolutional layers in the GAN generator model used (Dense, BatchNormalization, LeakyReLU, Reshape, and multiple Conv2DTranspose layers and Conv2DTranspose layer).

The convolutional layers of the GAN discriminator were designed as shown in Figure 3.7. The discriminator model is composed of Conv2D, LeakyReLU, Dropout, Flatten, and Dense layers.




Figure 3.7: Block diagram of the convolutional layers in the GAN discriminator model used (Conv2D, LeakyReLU, Dropout, Flatten, and Dense layers).

Table 3.6 presents the number of images per class for the test, training, and validation sets

for the axial slice group, including the images generated by the GAN in the training data. A total of one thousand images were generated for each class; subsequently, those that were likely incorrect and could impair training were removed.

Table 3.6: Number of test, training, and validation images per class, where class 1 corresponds to meningioma, class 2 to glioma, and class 3 to pituitary adenoma for approach of GAN. Of the images generated by the GAN, 20% were used for validation and 80% for training.

	Test	Training	Validation
Axial slice:			
Class 1 (meningioma)	37	454	113
Class 2 (glioma)	99	766	191
Class 3 (pituitary adenoma)	49	648	162

In this case, the generated data were tested using the same previous strategies, and the one that achieved the best performance results was selected.

3.6 METRICS USED IN PERFORMANCE EVALUATION

First, to calculate the performance evaluation metrics, the confusion matrix was computed. The matrix follows the model

$$\begin{bmatrix} T_P[1] & F_P[2] & F_P[3] \\ F_P[1] & T_P[2] & F_P[3] \\ F_P[1] & F_P[2] & T_P[3] \end{bmatrix}$$

where the rows represent the actual classes and the columns represent the predicted classes. Therefore, $T_P[1]$ represents the number of true positives for class 1, $T_P[2]$ the number of true positives for class 2, and $T_P[3]$ the number of true positives for class 3. Likewise, $F_P[1]$, $F_P[2]$, and $F_P[3]$ represent the number of false positives for classes 1, 2, and 3, respectively.

An algorithm was developed to find the values of T_P , F_P , and F_N , that is, the number of true positives, false positives, and false negatives, respectively, as illustrated in the diagram in Figure 3.8. The first step is to initialize the variables with zeros. Then, a loop iterates over the entire test vector, and another loop runs through the number of classes. If the actual value matches the predicted one, the corresponding class variable T_P is incremented. Otherwise, F_P and F_N are incremented for each corresponding class.

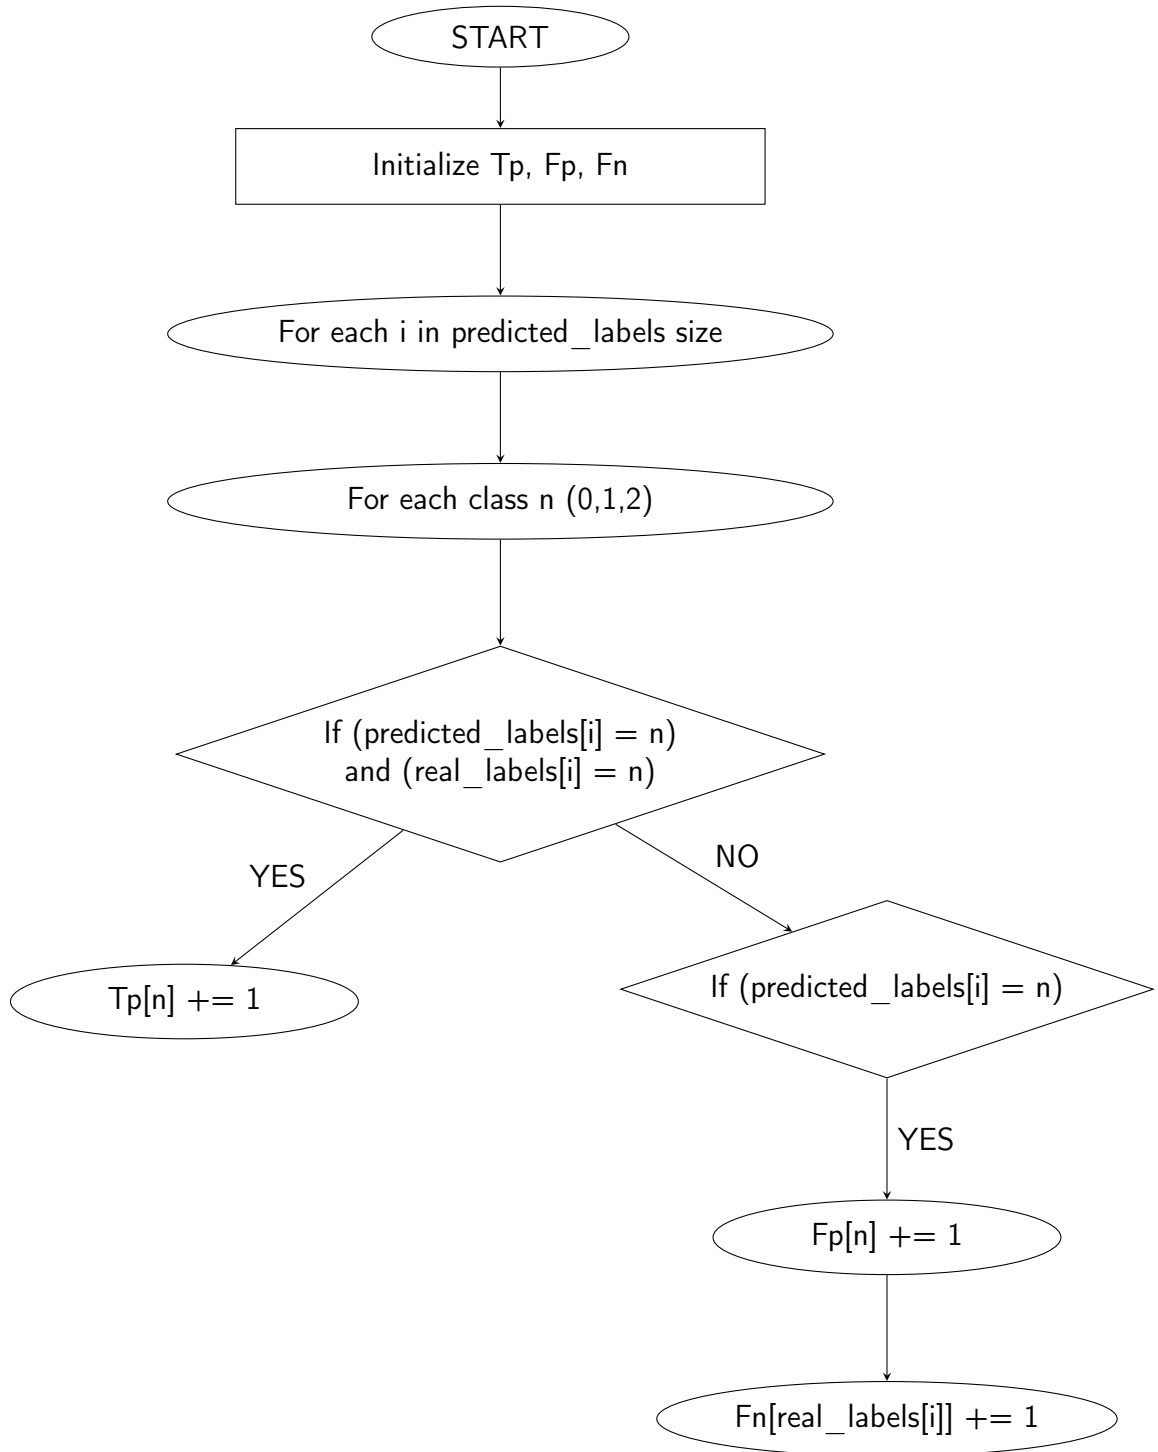


Figure 3.8: Flowchart representing how T_P , F_P and F_n are found.

The main performance metric used in this work was accuracy, calculated based on

$$Ac = \frac{\sum_{c=1}^3 T_P[c]}{\sum_{c=1}^3 (T_P[c] + F_P[c])}, \quad (3.1)$$

which is used to analyze a three-class problem, where T_P corresponds to true positives and F_P

represents false positives (samples incorrectly classified as class c when they actually belong to other classes), and c corresponds to each class.

In addition, the precision for class 1, class 2, and class 3 is calculated with, respectively,

$$P[1] = \frac{T_P[1]}{T_P[1] + F_P[1]}, \quad (3.2)$$

$$P[2] = \frac{T_P[2]}{T_P[2] + F_P[2]} \quad (3.3)$$

and

$$P[3] = \frac{T_P[3]}{T_P[3] + F_P[3]}. \quad (3.4)$$

$$P[c] = \frac{T_P[c]}{T_P[c] + F_P[c]}, \quad (3.5)$$

summarizes the precision calculation for all three classes.

$$P = \frac{\sum_{c=1}^3 P[c]}{3} \quad (3.6)$$

calculates the mean precision across all classes.

Equations

$$R[1] = \frac{T_P[1]}{T_P[1] + F_N[1]}, \quad (3.7)$$

$$R[2] = \frac{T_P[2]}{T_P[2] + F_N[2]} \quad (3.8)$$

and

$$R[3] = \frac{T_P[3]}{T_P[3] + F_N[3]} \quad (3.9)$$

calculate recall for each class, where $F_N[c]$ represents the false negatives for class c , corresponding to samples incorrectly classified as belonging to other classes when, in fact, they belong to class c .

$$R[c] = \frac{T_P[c]}{T_P[c] + F_N[c]} \quad (3.10)$$

provides a summary of the recall values. Then, the mean recall across all classes is calculated,

$$R = \frac{\sum_{c=1}^3 R[c]}{3}. \quad (3.11)$$

The F-score is calculated based on the precision and recall values,

$$F[c] = \frac{2P[c]R[c]}{P[c] + R[c]}. \quad (3.12)$$

Then, the mean F-score across all classes is calculated,

$$F = \frac{\sum_{c=1}^3 F[c]}{3}. \quad (3.13)$$

Finally, the averages of accuracy, precision, recall, and F-score are calculated. These results are then multiplied by 100 to express them as percentages.

In this study, the metrics of accuracy, precision, recall, and F-score were selected to evaluate the performance of the classification models. These metrics are commonly used together in scientific research as they enable a comprehensive performance analysis. However, when analyzed individually, these metrics can lead to misleading interpretations, as they do not fully reflect real performance in isolation. Therefore, the combination of these metrics allows a more reliable and realistic model evaluation, particularly in the medical field, to minimize the occurrence of false positives or false negatives in diagnoses.

RESULTS AND DISCUSSION

4.1 DATA AUGMENTATION TECHNIQUES - STRATEGY 1

Table 4.1 presents the test performance results of the CNN models with and without data augmentation, divided into analyses of all slices and only the axial slice.

The graph in Figure 4.1 presents the training and validation results obtained by the CNN using images from all slices, without data augmentation. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is shown as a function of the epoch.




Figure 4.1: Training (blue) and validation (orange) results obtained by the CNN using images from all slices, without data augmentation. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is presented as a function of the epoch.

In addition, the graphs in Figure 4.2 provide the training and validation results obtained by the pretrained CNN using images from all slices, without data augmentation.

The graphs in Figures 4.3, 4.4, and 4.5 present the training and validation results obtained by the CNN using only the axial slice — without data augmentation, with flip, and with flip and noise, respectively.

Table 4.1: Performance metrics for the classification of brain neoplasms from MRI images using customized and pretrained CNNs, including cases with data augmentation. Results are shown for all slices and for the axial slice only.

Method	Accuracy (%)	Precision (%)	Recall (%)	F-measure (%)
All slices				
Customized, Without data augmentation	77.9	77.0	74.7	75.8
Pretrained, Without data augmentation	88.7	90.6	85.5	88.0
Axial Slice				
Customized, Without data augmentation	85.8	82.2	81.6	81.9
Customized, Flip	85.2	88.0	77.9	82.6
Customized, Flip + Noise	85.2	87.4	76.5	81.6
Pretrained, Without data augmentation	85.2	81.6	80.9	81.2
Pretrained, Flip	85.8	83.8	82.4	83.1
Pretrained, Flip + Noise	88.4	84.3	84.9	84.6




Figure 4.2: Training (blue) and validation (orange) results obtained by the pre-trained CNN using images from all slices, without data augmentation. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is presented as a function of the epoch.




Figure 4.3: Training (blue) and validation (orange) results obtained by the CNN using only the axial slice, without data augmentation. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is presented as a function of the epoch.

Finally, the graphs in Figures 4.6, 4.7, and 4.8 present the training and validation results obtained by the pre-trained CNN using only the axial slice — without data augmentation, with flip, and with flip and noise, respectively.

Based on these results, the graph in Figure 4.1 illustrates that the accuracy and the loss function exhibited oscillations. Moreover, the accuracy values are not within a range considered relevant when compared to the results reported in the literature (Section 4.5), remaining below 85%.

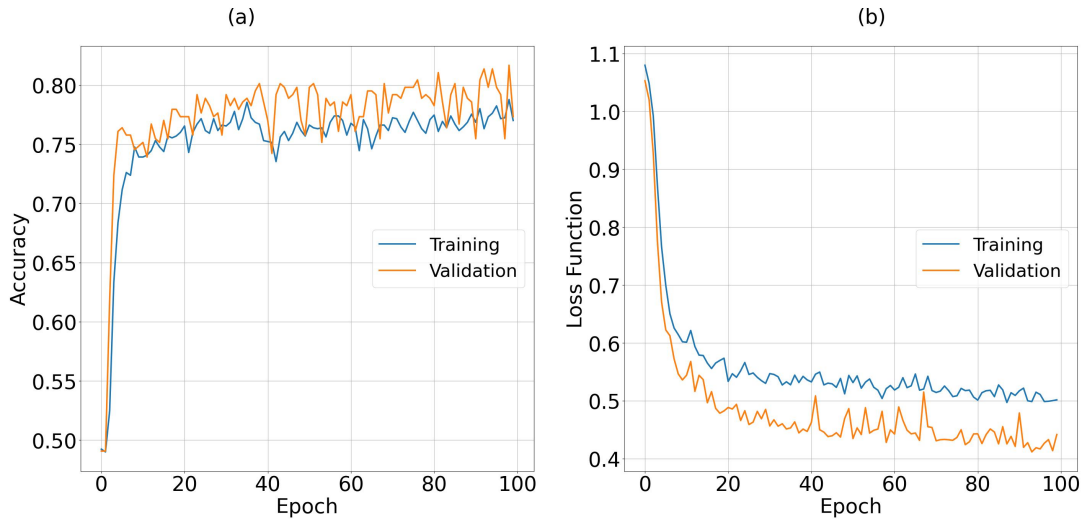


Figure 4.4: Training (blue) and validation (orange) results obtained by the CNN using only the axial slice, with data augmentation using flip. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is presented as a function of the epoch.




Figure 4.5: Training (blue) and validation (orange) results obtained by the CNN using only the axial slice, with data augmentation using flip and noise. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is presented as a function of the epoch.

In Figure 4.2, note that the results achieved were inferior to those obtained with the customized CNN architecture, because relevant gap between the training and validation curves likely indicates overfitting. This happens when the model learns the training data too well but fails to generalize to validation data, when the complexity of the models used is greater than necessary for this specific application.

In contrast, the graphs in Figures 4.3, 4.4, and 4.5 (using only axial images) indicate probable underfitting, where the training curve lies expressive below the validation curve. This occurs




Figure 4.6: Training (blue) and validation (orange) results obtained by the pre-trained CNN using only the axial slice, without data augmentation. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is presented as a function of the epoch.




Figure 4.7: Training (blue) and validation (orange) results obtained by the pre-trained CNN using only the axial slice, with data augmentation using flip. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is presented as a function of the epoch.

when the model is too simple or insufficiently trained. Meanwhile, the graphs in Figures 4.6, 4.7, and 4.8 display results with less underfitting compared to all previous cases, especially those employing data augmentation (noise and flip).

Therefore, the results obtained by analyzing only the axial slice images were generally better than those obtained by analyzing all slices together. Furthermore, the model using data augmentation with flip and noise, based on a pre-trained architecture and trained only on the axial slice, achieved the best result, with 88.4% accuracy; 84.3% precision ; 84.9% recall; and




Figure 4.8: Training (blue) and validation (orange) results obtained by the pretrained CNN using only the axial slice, with data augmentation using flip and noise. In ‘(a)’, the accuracy is shown as a function of the epoch, and in ‘(b)’, the loss function is presented as a function of the epoch.

84.6% F-score, as shown in Table 4.1 and Figure 4.8.

Thus, the data augmentation techniques employed in this stage of the research, as described in Section 4.1, did not improve the results according to the applied methodology compared with those reported in the literature, as presented in Section 4.5.

4.2 CLASSIFICATION OF FEATURE EXTRACTION USING CNN (AXIAL SLICE ONLY) - STRATEGY 2

Tables 4.2 to 4.8 present the average performance metrics for database classifications using as input the features extracted through CNNs: DenseNet121, MobileNet, EfficientNetV2 B0, Inception V3, and Xception. Each table shows the performance results of the classifiers in descending order of accuracy.

In this stage, to avoid the occurrence of overfitting, the k-fold method was employed, with $k = 10$, which is commonly used in the literature. Furthermore, the best results were achieved using features extracted with MobileNet, after applying dimensionality reduction, and classified using an MLP, reaching an accuracy of 94%. Additionally, the MLP classifier showed superior performance in most of the results obtained with the different feature extraction models.

To compare cases with and without dimensionality reduction, Tables 4.2 and 4.3 were included. Dimensionality reduction did not cause relevant differences in results. However, in the examples using the DenseNet121 model, the total computational time for training and testing was reduced from 4 minutes and 6 seconds to 1 minute and 14 seconds in the case with dimensionality reduction. This reduction in computational cost may be advantageous, for example, by facilitating the training of classification systems, optimizing related studies; by improving the development of embedded systems; and by reducing the energy required to operate these applications. Similarly, in the Xception results (Tables 4.7 and 4.8), the total time was reduced from 7 minutes and 12 seconds to 1 minute and 19 seconds for the example with dimensionality reduction. Therefore, the remaining tables present results obtained with dimensionality reduction.

Logistic Regression was the classifier model with the highest computational cost among all tested. Moreover, the total time was mainly due to the classification time.

Table 4.2: Average performance metrics for classifications using DenseNet121 to extract features. Classification without dimensionality reduction. **Total execution time (training and testing):** 4 minutes and 6 seconds.

Classifier	Accuracy(%)	Precision(%)	Recall(%)	F1-Score(%)	Time (s)
MLP	89.4	86.6	86.9	86.7	52.4
Logistic Regression	87.7	83.9	84.9	84.4	125.0
Linear Discriminant Analysis	84.5	81.2	79.4	80.3	5.69
SVM	88.2	85.1	85.5	85.3	4.4
SGDC	88.6	85.8	86.2	86.0	1.2
K Neighbors Classifier	81.3	76.2	77.2	76.7	0.6
Bagging Classifier	91.7	90.3	88.9	89.6	34.2
Extra Trees Classifier	91.2	91.5	87.1	89.3	7.1
Decision Tree Classifier	87.4	85.4	83.9	84.6	6.6
Gaussian NB	82.9	78.5	80.9	79.7	0.5
Random Forest Classifier	82.6	88.9	72.1	79.6	6.2
Quadratic Discriminant Analysis	54.7	50.4	50.4	50.4	1.93

4.3 TRANSFER LEARNING (AXIAL SLICE ONLY) - STRATEGY 3

Table 4.9 presents the performance metrics using DenseNet121 for different slices (axial, sagittal, and coronal). The axial slice achieved the best performance results. Therefore, this work mainly focused on the analysis of the axial slice. In this table, 80% of the data were separated for training (20% of the training images were used for validation) and 20% for testing. The image size was defined as 256x256, and the training consisted of 500 epochs.

Table 4.3: Average performance metrics for classifications using DenseNet121 to extract features. Classification with dimensionality reduction. **Total execution time (training and testing): 1 minute and 14 seconds.**

Classifier	Accuracy(%)	Precision(%)	Recall(%)	F1-Score(%)	Time (s)
MLP	88.9	85.5	86.7	86.1	15.1
Logistic Regression	88.5	84.7	86.0	85.4	33.1
Linear Discriminant Analysis	91.2	88.8	88.5	88.6	1.3
SVM	87.7	84.8	84.3	84.6	2.4
SGDC	87.4	85.4	84.3	84.8	0.5
K Neighbors Classifier	81.0	75.7	76.6	76.1	0.2
Bagging Classifier	76.9	71.6	71.9	71.8	10.6
Extra Trees Classifier	76.1	79.2	63.6	70.5	5.2
Decision Tree Classifier	71.8	65.6	65.9	65.8	2.1
Gaussian NB	74.5	70.1	73.0	71.5	0.2
Random Forest Classifier	54.9	–	35.1	–	3.2
Quadratic Discriminant Analysis	53.5	–	33.3	–	0.60

Table 4.4: Average performance metrics for classifications using MobileNet to extract features. Classification with dimensionality reduction.

Classifier	Accuracy(%)	Precision(%)	Recall(%)	F1-Score(%)
MLP	94.0	93.0	91.9	92.4
Logistic Regression	92.9	90.9	91.1	91.0
Linear Discriminant Analysis	92.7	91.2	90.5	90.9
SVM	92.7	90.9	90.4	90.6
SGDC	91.1	90.9	87.7	89.3
K Neighbors Classifier	87.7	84.6	84.8	84.7
Bagging Classifier	82.9	77.5	78.7	78.1
Extra Trees Classifier	81.1	85.4	69.8	76.8
Decision Tree Classifier	79.0	73.8	74.3	74.1
Gaussian NB	78.6	77.5	72.1	74.7
Random Forest Classifier	54.5	–	34.6	–
Quadratic Discriminant Analysis	53.5	–	33.3	–

Table 4.5: Average performance metrics for classifications using EfficientNet V2 B0 to extract features. Classification with dimensionality reduction.

Classifier	Accuracy(%)	Precision(%)	Recall(%)	F1-Score(%)
MLP	87.1	83.6	84.0	83.8
Logistic Regression	89.0	86.0	87.2	86.6
Linear Discriminant Analysis	82.4	78.2	79.2	78.7
SVM	85.4	83.3	81.1	82.2
SGDC	87.2	84.1	84.9	84.5
K Neighbors Classifier	79.0	74.9	75.0	74.9
Bagging Classifier	73.4	66.8	66.7	66.7
Extra Trees Classifier	77.7	82.5	65.4	72.9
Decision Tree Classifier	67.6	62.5	63.0	62.7
Gaussian NB	60.1	56.0	56.6	56.3
Random Forest Classifier	59.2	–	40.6	–
Quadratic Discriminant Analysis	53.5	–	33.3	–

Table 4.6: Average performance metrics for classifications using Inception V3 to extract features. Classification with dimensionality reduction.

Classifier	Accuracy(%)	Precision(%)	Recall(%)	F1-Score(%)
MLP	93.5	92.2	92.3	92.2
Logistic Regression	91.8	90.4	90.2	90.3
Linear Discriminant Analysis	92.8	91.0	92.3	91.6
SVM	91.7	90.1	89.4	89.8
SGDC	89.2	88.3	85.8	87.0
K Neighbors Classifier	85.2	83.2	81.4	82.3
Bagging Classifier	80.3	77.8	75.4	76.6
Extra Trees Classifier	76.1	86.1	62.7	72.6
Decision Tree Classifier	75.3	71.3	71.2	71.3
Gaussian NB	70.8	67.3	64.7	66.0
Random Forest Classifier	55.3	–	35.6	–
Quadratic Discriminant Analysis	53.5	–	33.3	–

Table 4.7: Average performance comparison of classifiers using Xception to extract features. Classification without dimensionality reduction. Execution time of each classifier in seconds. **Total execution time (training and testing): 7 minutes and 12 seconds.**

Classifier	Accuracy(%)	Precision(%)	Recall(%)	F1-Score(%)	Time (s)
MLP	89.0	87.5	85.6	86.5	68.3
Logistic Regression	88.2	85.8	84.5	85.1	248.4
Linear Discriminant Analysis	87.1	84.5	85.2	84.9	6.1
SVM	86.4	84.9	83.1	84.0	10.0
SGDC	88.1	86.4	84.6	85.5	2.2
K Neighbors Classifier	86.0	82.7	83.6	83.1	1.0
Bagging Classifier	82.3	80.7	79.0	79.9	61.8
Extra Trees Classifier	85.3	85.4	79.7	82.4	11.3
Decision Tree Classifier	75.5	72.9	72.4	72.6	12.4
Gaussian NB	82.2	78.0	79.1	78.6	0.8
Random Forest Classifier	75.8	–	61.4	–	7.0
Quadratic Discriminant Analysis	47.9	41.5	41.3	41.4	3.3

Table 4.8: Average performance comparison of classifiers using Xception to extract features. Classification with dimensionality reduction. Execution time of each classifier in seconds. **Total execution time (training and testing): 1 minute and 19 seconds.**

Classifier	Accuracy(%)	Precision(%)	Recall(%)	F1-Score(%)	Time (s)
MLP	89.0	87.0	85.7	86.4	17.0
Logistic Regression	88.5	85.9	84.7	85.3	32.7
Linear Discriminant Analysis	88.8	85.6	86.1	85.8	0.6
SVM	87.1	84.8	83.4	84.1	1.9
SGDC	87.7	86.3	83.2	84.7	0.4
K Neighbors Classifier	86.0	82.7	83.6	83.1	0.2
Bagging Classifier	80.2	77.9	74.7	76.2	14.1
Extra Trees Classifier	77.5	87.7	64.7	74.5	5.7
Decision Tree Classifier	74.0	71.3	70.4	70.9	2.1
Gaussian NB	76.3	78.9	67.1	72.5	0.3
Random Forest Classifier	55.2	–	35.4	–	3.6
Quadratic Discriminant Analysis	53.5	–	33.3	–	0.6

Table 4.9: Performance metrics for the classification of brain neoplasms (glioma, meningioma, and pituitary adenomas) in magnetic resonance images using Transfer Learning (DenseNet121) for each slice separately (axial, sagittal, coronal).

Slice	Accuracy (%)	Precision (%)	Recall (%)	F-score (%)
Axial	95.1	93.8	92.3	92.9
Sagittal	91.9	91.6	92.2	91.8
Coronal	90.3	88.8	90.8	89.6

Table 4.10 presents the performance metrics obtained from different Transfer Learning models using only axial slice images. DenseNet121 achieved the best performance results among all Transfer Learning techniques and even surpassed the other techniques discussed in the previous sections of this work. In this table, 80% of the data were separated for training (10% of the training images were used for validation) and 20% for testing. The image size was defined as 224x224, and the training was conducted for 150 epochs.

Table 4.10: Performance metrics for brain neoplasm classification (glioma, meningioma, and pituitary adenomas) in magnetic resonance images using Transfer Learning.

Classifier	Accuracy (%)	Precision (%)	Recall (%)	F-score (%)
DenseNet121	96.8	96.8	94.8	95.6
MobileNet	95.7	95.8	93.2	94.2
EfficientNetV2 B0	91.9	91.5	89.7	90.5
Inception V3	90.8	91.9	85.6	87.4
Xception	90.8	90.8	86.2	88.0

The graphs in Figure 4.9 present the training and validation results obtained through Transfer Learning using DenseNet121 and only the axial slice. The initial oscillation, both training and validation values stabilize after around 60 epochs, with a lower incidence of overfitting.

This model, which achieved the best results, can also be analyzed and confirmed in the confusion matrix shown in Figure 4.10, where the highest percentages are along the main diagonal, indicating that, particularly for the glioma class, the results were correctly classified during the testing stage. This likely occurred due to the larger number of training and testing samples from MRI scans of patients with glioma.

Furthermore, it is observed that 10.8% of the meningioma images were misclassified as pituitary adenomas. This may have occurred because some types of meningiomas can be




Figure 4.9: Training and validation results obtained through Transfer Learning using DenseNet121 and only the axial slice. In ‘(a)’ is the accuracy as a function of epochs, and in ‘(b)’ is the loss function as a function of epochs.

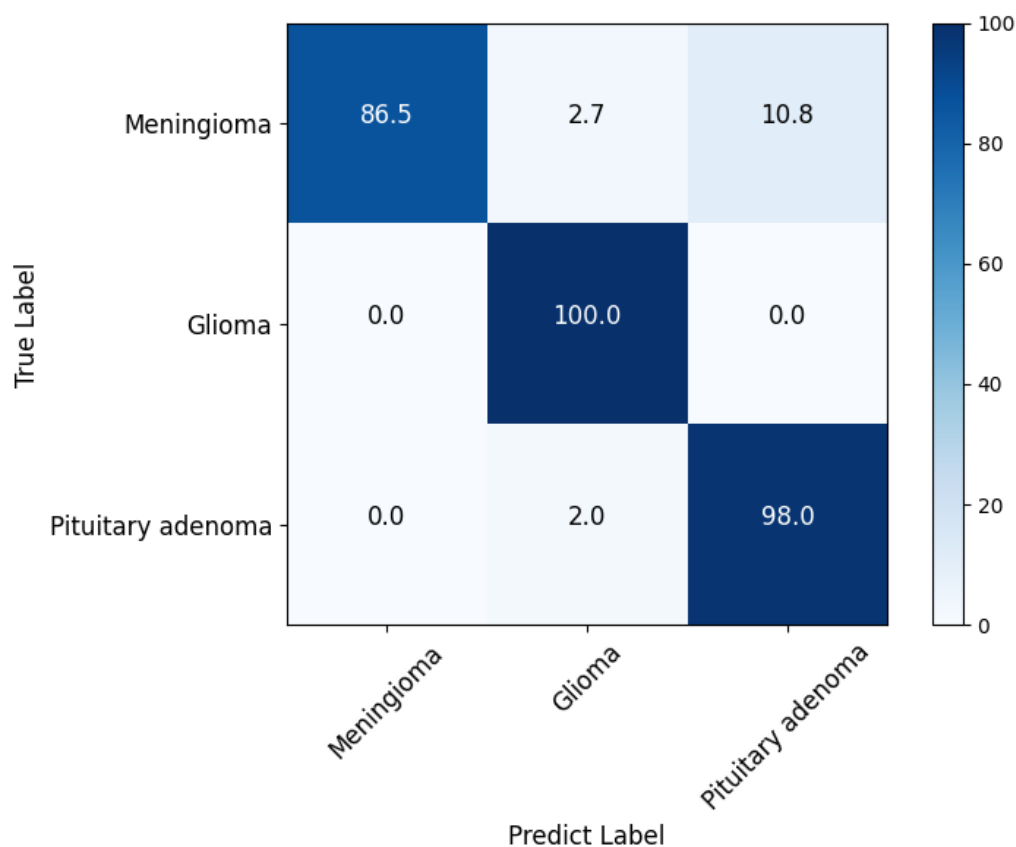


Figure 4.10: Confusion matrix obtained for the DenseNet121 model using Transfer Learning, in percentage (%). Axial slice with three distinct classes: meningioma, glioma, and pituitary adenomas.

located near the pituitary region, thereby confusing the classifier. Similarly, images that were incorrectly classified as glioma, due to the diversity of glioma types, may also have led to

classifier confusion.

Figures 4.11, 4.12, 4.13, and 4.14 present the training and validation results obtained through Transfer Learning MobileNet, EfficientNet B0, Inception V3, and Xception, respectively, all analyzing only the axial slice.




Figure 4.11: Training and validation results obtained through Transfer Learning using MobileNet and only the axial slice. ‘(a)’ exhibits the accuracy as a function of epochs, and ‘(b)’ presents the loss function as a function of epochs.




Figure 4.12: Training and validation results obtained through Transfer Learning EfficientNetV2 B0 and only the axial slice. ‘(a)’ exhibits the accuracy as a function of epochs, and ‘(b)’ presents the loss function as a function of epochs.

Therefore, Transfer Learning achieved the best performance results among all the strategies evaluated in this research, particularly when using DenseNet121. However, Transfer Learning




Figure 4.13: Training and validation results obtained through Transfer Learning Inception V3 and only the axial slice. ‘(a)’ exhibits the accuracy as a function of epochs, and ‘(b)’ presents the loss function as a function of epochs.

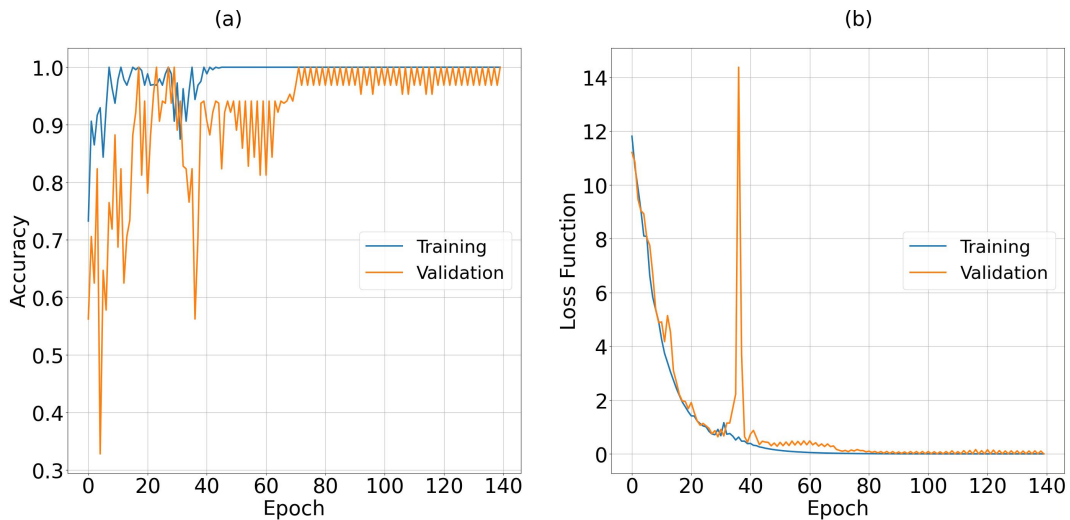


Figure 4.14: Training and validation results obtained through Transfer Learning using Xception and only the axial slice. ‘(a)’ exhibits the accuracy as a function of epochs, and ‘(b)’ presents the loss function as a function of epochs.

requires a higher number of epochs for the stabilization of the training and validation curves compared to data augmentation strategies using pretrained CNN architectures, both evaluated using only axial slice images.

Note that even when using only axial slice images, the models achieved sufficiently expressive performance compared to the other analyses. Thus, this type of strategy becomes relevant in studies focused on brain neoplasm classification. This result demonstrates that it is possible to reduce the number of training images without loss in performance.

Finally, the Transfer Learning strategy not only outperformed the previous techniques explored in this work but also demonstrated robustness against the risk of overfitting. Therefore, these performance results reinforce the relevance of using CNN in Transfer Learning strategies as an effective approach for the automatic classification of brain tumors in magnetic resonance images.

4.4 GENERATIVE ADVERSARIAL NETWORK

Finally, images were generated to train the same previous convolutional networks using a Generative Adversarial Network (GAN), to compare the obtained results. After several GAN training sessions, the loss as a function of each epoch (3000 in total) was obtained, as shown in the graph in Figure 4.15.

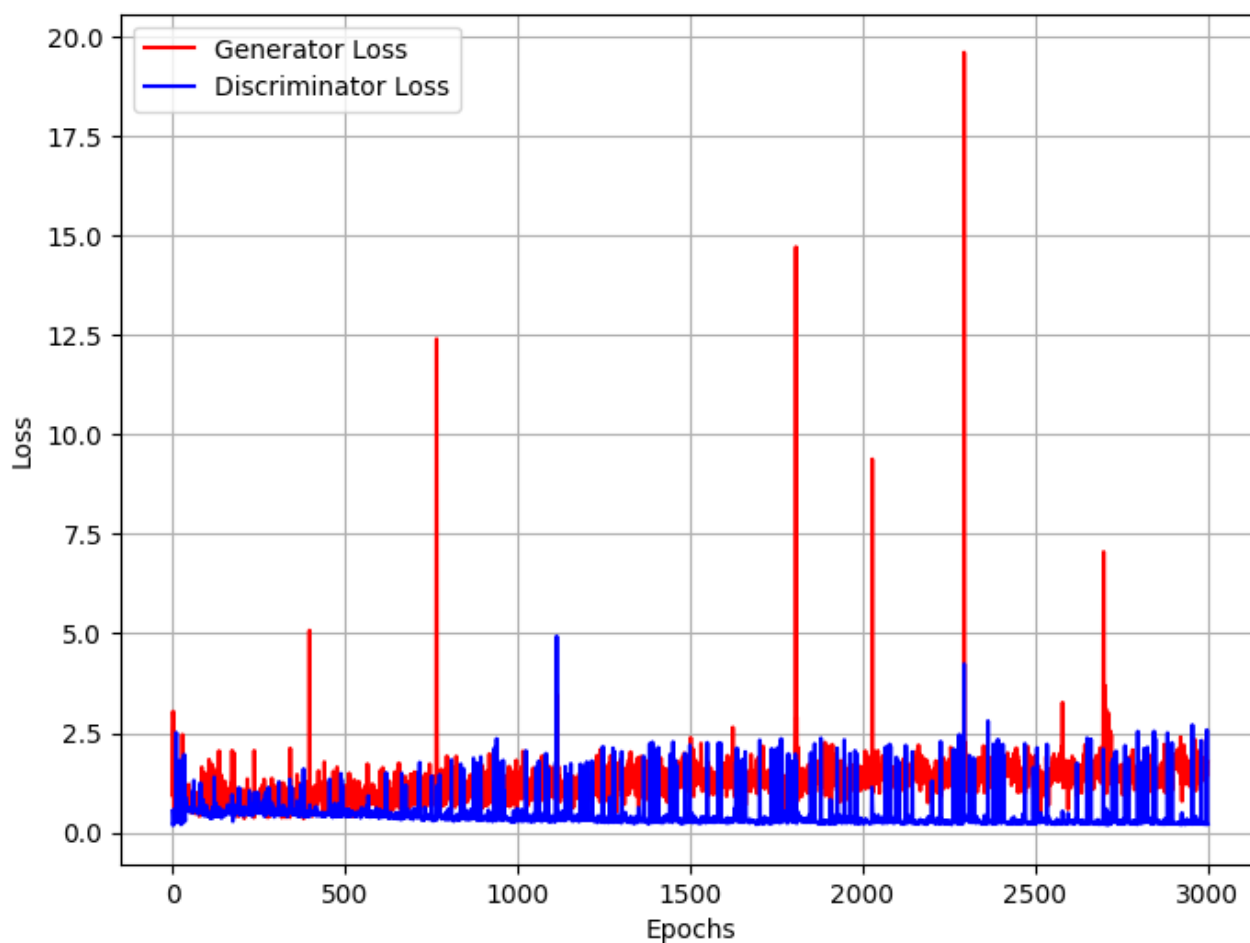


Figure 4.15: Graph of the results obtained from image generation using a Generative Adversarial Network showing the loss as a function of the epoch.

Moreover, examples of images generated for each class type are shown in Figure 4.16, with the meningioma class on the left, the glioma class in the center, and the pituitary adenoma class on the right.




Figure 4.16: Examples of the three MRI classes generated by the GAN from different patients (left: meningioma; center: glioma; right: pituitary adenoma).

Even with the presence of noise, the generated images exhibited tumor regions according to the class of the real input data. However, the glioma class produced images in which the presence of the tumor was more difficult to detect, even visually, which may have hindered the image classification process.

Table 4.11 presents the best results obtained using images generated by the GAN as a data augmentation strategy with pre-trained networks, considering only the axial slice, without additional augmentation, and using VGG16, as described in Strategy 1 in Section 4.1.

Table 4.11: Performance metrics for the classification of brain neoplasms (glioma, meningioma, and pituitary adenoma) in MRI images using images generated by a Generative Adversarial Network with a pre-trained network strategy (Section 4.1).

Classifier	Accuracy (%)	Precision (%)	Recall (%)	F-score (%)
VGG16	90.3	86.4	89.2	87.8

For Table 4.11, the graph in Figure 4.17 shows the training and validation results obtained by the pretrained CNN using images generated by the GAN.

Thus the performance metrics obtained using GAN-generated images did not achieved those obtained with real image classification (Table 4.10). Nevertheless, the relevant results indicate that it is possible to use this type of image generation for the development of a brain neoplasm




Figure 4.17: Training (blue) and validation (orange) results obtained by the pre-trained CNN using only the axial slice. ‘(a)’ accuracy shows as a function of the epoch, and ‘(b)’ presents the loss function as a function of the epoch.

classification system.

4.5 SCIENTIFIC RESEARCH ADDRESSED IN THE STATE OF THE ART

References that used this database include (MONDAL; SHRIVASTAVA, 2022), (CHENG *et al.*, 2015), (CHENG *et al.*, 2016), (TALUKDER *et al.*, 2023), (ZULFIQAR *et al.*, 2023), (HAQ *et al.*, 2023), and (BISWAS; ISLAM, 2023).

The CNN was used in a hold-out validation and achieved an accuracy of 99.6%, while cross-validation yielded an accuracy of 98.4% (MONDAL; SHRIVASTAVA, 2022). In addition, a study tested an enlarged tumor region as the Region of Interest (ROI) and observed an improvement in accuracy. Using the intensity histogram, the accuracy increased from 71.4% to 82.3%; the GLCM accuracy increased from 78.2% to 84.7%; and the accuracy of the Bag of Words (BoW) model increased from 83.5% to 88.2% (CHENG *et al.*, 2015).

Another study, also by researchers from the School of Biomedical Engineering at Southern Medical University in Guangzhou, China achieved an accuracy of 94.7% using the same database (CHENG *et al.*, 2016).

A study that used a deep learning model to categorize brain neoplasms achieved an accu-

racy of 99.7% by employing ResNet50V2 with the same database used for the development of this dissertation (TALUKDER *et al.*, 2023). Using EfficientNetB2, the accuracy reached 98.9% (ZULFIQAR *et al.*, 2023). Another work employing a CNN architecture achieved an accuracy of 97.3% (HAQ *et al.*, 2023). Furthermore, an investigation using this same database reported an accuracy of 96.0% (BISWAS; ISLAM, 2023).

In another analysis, brain neoplasms were classified using a Deep Convolutional Neural Network (CNN) with transfer learning, employing a pretrained GoogLeNet for feature extraction. This research used five-fold cross-validation, resulting in an average classification accuracy of 98% (DEEPAK; AMEER, 2019).

Another experiment that focused on brain tumor classification using CNN achieved a training accuracy of 98.5 and validation accuracy of 84.2% (ABIWINANDA *et al.*, 2019).

In another project, transfer learning was employed for brain neoplasm classification using DL, achieving an accuracy of 98.7% (REHMAN *et al.*, 2019). In a similar transfer learning application, the study achieved an average precision of 96.1% using five-fold cross-validation (SWATI *et al.*, 2019).

In a study conducted by another research team, the use of CNN in the same application resulted in an accuracy of 96.6% (BADŽA; BARJAKTAROVIĆ, 2020). In addition, a study focused on a DL approach for the classification and segmentation of brain neoplasms using a multiscale CNN achieved an accuracy of 97.3% (DÍAZ-PERNAS *et al.*, 2021).

Another article discusses a hybrid feature extraction method combined with a regularized extreme learning machine for brain tumor classification, achieving an accuracy ranging from 91.5% to 94.2% (GUMAEI *et al.*, 2019).

Major references in the area are listed in Table 4.12 to compare the methodologies and results of each study and summarize the information from each publication. In addition to the references on brain neoplasm detection using machine learning that employed the same dataset as this work, there are numerous other studies on this topic using different datasets.

One article discusses ensemble learning for brain classification using MRI (VAIYAPURI *et al.*, 2023). Another approach to brain tumor detection uses the GAN to enhance image resolution. In that study, accuracy, F-measure, precision, recall, and area under the ROC

curve all reached approximately 100% in specific cases (MOHSEN *et al.*, 2023). Several other recent studies have presented the use of GANs to improve brain neoplasm image classification (KARPAKAM; KUMARESHAN, 2025; ALMUHAIMI *et al.*, 2025; VURE; PAPPALA, 2025; AFIF *et al.*, 2025).

4.6 GENERAL DISCUSSION OF THE RESULTS

The results of some models produced values below expectations, and occurrences of overfitting and underfitting were observed when using traditional data augmentation techniques. On the other hand, the use of transfer learning with real images provided better performance result, in addition to the use of data augmentation strategies reported in the state of the art. The results obtained using CNNs were close to those achieved in other studies found in the literature, which considers all slices simultaneously. Therefore, the strategies employed in scenarios with limited data, evaluating only axial slice images, particularly CNNs using transfer learning, proved to be effective.

However, some images were incorrectly classified, likely because certain types of meningiomas may be located near the pituitary region, thereby confusing the classifier. In addition, images containing glioma, due to the diversity of its types, may also have compromised the training process.

Nevertheless, among the strategies evaluated, the transfer learning technique proved to be the most efficient, especially the performance metrics obtained. This is consistent with what has been reported in the literature (REHMAN *et al.*, 2019; SWATI *et al.*, 2019). The use of transfer learning models, especially DenseNet121, ensured superior performance across all evaluated metrics. These results achieved average accuracy values of up to 96.8%, with precision reaching 96.8%, recall of 94.8%, and an F-measure of 95.6%, using the DenseNet121 model, demonstrating that this approach is capable of extracting relevant features even in a scenario restricted to the axial slice, thus going beyond what has been reported in the literature.

Therefore, this work not only confirms the effectiveness of using advanced deep learning architectures for image-based diagnosis but also expands the scope of the literature by demonstrating that the application of transfer learning to isolated axial data can transcend or,

at least, match the results achieved by methodologies that consider multiple MRI sequences and slices (MONDAL; SHRIVASTAVA, 2022), (CHENG *et al.*, 2015), (CHENG *et al.*, 2016), (TALUKDER *et al.*, 2023), (ZULFIQAR *et al.*, 2023), (HAQ *et al.*, 2023) e (BISWAS; ISLAM, 2023).

Thus, the experiments conducted contribute to advancing the understanding, study, training, and validation of techniques applied to the recognition of brain neoplasms, consolidating transfer learning as the most promising strategy in this context, corroborating what is presented in the literature (DEEPAK; AMEER, 2019; REHMAN *et al.*, 2019; SWATI *et al.*, 2019).

In addition to employing images generated through data augmentation strategies during the the training phase of these networks, as also reported in the state of the art (MOHSEN *et al.*, 2023; KARPAKAM; KUMARESHAN, 2025; ALMUHAIMEED *et al.*, 2025; VURE; PAPPALA, 2025; AFIF *et al.*, 2025), this study systematically evaluated their impact on classification performance. Furthermore, the results obtained using image generation with Generative Adversarial Networks were not superior to the highest transfer learning results. However, they were relevant, achieving an average accuracy of up to 90.3%, precision of up to 86.4%, recall of up to 89.2%, and F-measure of up to 87.8%, using pre-trained networks and the VGG16 model.

The results obtained in this work, presented in the previous sections, are comparable, and in some cases superior, to those reported in the literature. However, no study was identified that specifically explored the classification of brain neoplasms using exclusively axial slice images, under the same conditions, parameters, and strategies proposed here. This methodological choice demonstrates that, even when restricting the analysis to a single acquisition plane, it was possible to achieve robust metrics comparable to more complex approaches. Furthermore, during the analyses conducted in this study, careful measures were taken to prevent data leakage, an aspect that was not explicitly mentioned in the scientific articles found in the literature.

The fact that these strategies, despite being applied to limited amounts of data, achieved relevant performance results indicates that it is possible to improve classifier efficiency while also reducing computational cost due to reduced training time. Such a scenario facilitates the reproducibility of experiments and optimizes the application of these approaches to the analysis

of other databases and applications with limited numbers of images.

Table 4.12: Studies using the dataset (CHENG, 2017) for MRI-based classification of three diseases (meningioma, glioma, and pituitary adenoma) — showing the best average accuracy (%) and the type of models used.

Referência	Modelo	Ac.(%)
(MONDAL; SHRIVASTAVA, 2022)	CNN (BMRI-Net) - Hold-out	99.6
(NOREEN <i>et al.</i> , 2020)	DensNet201	99.5
(NOREEN <i>et al.</i> , 2020)	Inception-v3	99.3
(SAHOO <i>et al.</i> , 2023)	progressive growing GAN (PGGAN)	98.8
(DEEPAK; AMEER, 2019)	Pre-trained GoogLeNet to extract features, Five-fold cross-validation	98,0
(CHENG <i>et al.</i> , 2016)	augment the tumor region, adaptive spatial division method, Fisher kernel framework	94.7
(GUMAEI <i>et al.</i> , 2019)	PCA-NGIST and Regularized extreme learning machine (RELM), random holdout	94.2
(CHENG <i>et al.</i> , 2015)	ring-form partition- BoW model	91.3
(ANAGUN, 2023)	2D Convolutional Neural Network (CNN)	91.3

CONCLUSION

This study consisted of a systematic investigation into the development of a medical diagnostic support system, employing classification models and data augmentation strategies. The approach was based on different brain MRI classifiers using images, applying algorithms to assist in the diagnosis of brain neoplasms, specifically to identify three distinct types: meningioma, glioma, and pituitary adenomas.

Given the relevant performance of the models, it is important to mention the clinical implications of the findings. The applicability of these techniques may represent a substantial advancement in helping to diagnose brain neoplasms, contributing to faster and more accurate clinical decisions, which could also be obtained through incidental findings. In summary, this study demonstrated that it is possible to select simpler architectures that can be trained on smaller datasets by analyzing only a single slice (in this case, the axial slice), while also employing data augmentation strategies.

Therefore, based on the systematic evaluations conducted, it can be observed that the strategies adopted in this study may contribute to scientific advances in other AI applications in brain MRI beyond this specific case, which focused on brain neoplasm analysis. In addition to the approaches and applications presented in the literature, that have limited amounts of data. This situation also reduces computational cost, optimizing the use of these approaches.

In this context, a proposal for future work would be to investigate image generation and including classifications with the goal of achieving performance results superior to those obtained in this study, including in other applications. Furthermore, another possible direction for future work would be the evaluation of the complexity of the solutions, including processing requirements and energy consumption, which may be useful, for example, in embedded systems.

REFERENCES

ABIWINANDA, N.; HANIF, M.; HESAPUTRA, S. T.; HANDAYANI, A.; MENGKO, T. R. Brain Tumor Classification Using Convolutional Neural Network. Springer Singapore, p. 183–189, 2019. Available at: <http://dx.doi.org/10.1007/978-981-10-9035-6_33>. Cited on page 57.

AFIF, M. M.; NOMAN, A. A.; KABIR, K. M. T.; AHMMED, M. M.; RAHMAN, M. M.; MAHMUD, M.; BABU, M. A. *Proportional Sensitivity in Generative Adversarial Network (GAN)-Augmented Brain Tumor Classification Using Convolutional Neural Network*. 2025. Available at: <<https://arxiv.org/abs/2506.17165>>. Cited 2 times on pages 58 and 59.

AGGARWAL, C. *Neural Networks and Deep Learning: A Textbook*. Springer International Publishing, 2018. ISBN 9783319944647. Available at: <<https://books.google.com.br/books?id=AsTswQEACAAJ>>. Cited on page 21.

AHMAD, B.; SUN, J.; YOU, Q.; PALADE, V.; MAO, Z. Brain tumor classification using a combination of variational autoencoders and generative adversarial networks. *Biomedicines*, MDPI, v. 10, n. 2, p. 1–19, 2022. Cited on page 25.

AIZENBERG, I.; AIZENBERG, N. N.; VANDEWALLE, J. P. *Multi-Valued and Universal Binary Neurons: Theory, Learning and Applications*. [S.l.]: Springer Science & Business Media, 2000. Cited on page 21.

AKINYELU, A. A.; ZACCAGNA, F.; GRIST, J. T.; CASTELLI, M.; RUNDO, L. Brain Tumor Diagnosis Using Machine Learning, Convolutional Neural Networks, Capsule Neural Networks and Vision Transformers, Applied to MRI: A Survey. *Journal of Imaging*, v. 8, n. 8, p. 205, July 2022. ISSN 2313-433X. Available at: <<https://www.mdpi.com/2313-433X/8/8/205>>. Cited on page 5.

ALBALAWI, E.; T.R, M.; THAKUR, A.; KUMAR, V. V.; GUPTA, M.; KHAN, S. B.; ALMUSHARRAF, A. Integrated approach of federated learning with transfer learning for classification and diagnosis of brain tumor. *BMC Medical Imaging*, v. 24, n. 1, p. 1–15, 2024. ISSN 14712342. Cited on page 2.

ALMUHAIMEED, A.; BILAL, A.; ALZHRANI, A.; ALRASHIDI, M.; ALGHAMDI, M.; SARWAR, R. Brain tumor classification using GAN-augmented data with autoencoders and Swin Transformers. *Frontiers in Medicine*, v. 12, n. August, p. 1–26, August 2025. ISSN 2296-858X. Available at: <<https://www.frontiersin.org/articles/10.3389/fmed.2025.1635796/full>>. Cited 2 times on pages 58 and 59.

ALPAYDIN, E. *Introduction to Machine Learning*. 3. ed. Cambridge, MA: MIT Press, 2014. (Adaptive Computation and Machine Learning). ISBN 978-0-262-02818-9. Cited 2 times on pages 18 and 20.

- ALRASHEDY, H. H. N.; ALMANSOUR, A. F.; IBRAHIM, D. M.; HAMMOUDEH, M. A. A. BrainGAN: Brain MRI Image Generation and Classification Framework Using GAN Architectures and CNN Models. *Sensors (Basel, Switzerland)*, MDPI, v. 22, n. 11, p. 4297, 2022. Cited on page 25.
- ALRUMIAH, S. S.; ALREBDI, N.; IBRAHIM, D. M. Augmenting healthy brain magnetic resonance images using generative adversarial networks. *PeerJ Computer Science*, v. 9, p. e1318, 2023. Available at: <<https://doi.org/10.7717/peerj-cs.1318>>. Cited on page 25.
- AMIN, J.; SHARIF, M.; HALDORAI, A.; YASMIN, M.; NAYAK, R. S. Brain tumor detection and classification using machine learning: a comprehensive survey. *Complex Intelligent Systems*, Springer International Publishing, v. 8, n. 4, p. 3161–3183, August 2022. ISSN 2199-4536. Available at: <<https://doi.org/10.1007/s40747-021-00563-yhttps://link.springer.com/10.1007/s40747-021-00563-y>>. Cited on page 3.
- ANAGUN, Y. Smart brain tumor diagnosis system utilizing deep convolutional neural networks. *Multimedia Tools and Applications*, Springer US, n. 0123456789, 2023. ISSN 15737721. Available at: <<https://doi.org/10.1007/s11042-023-15422-w>>. Cited 2 times on pages 2 and 61.
- ANITA, J. N.; KUMARAN, S. A Deep Learning Architecture for Meningioma Brain Tumor Detection and Segmentation. *Journal of Cancer Prevention*, v. 27, n. 3, p. 192–198, 2022. ISSN 2288-3649. Cited on page 2.
- ARIF, M.; AJESH, F.; SHAMSUDHEEN, S.; GEMAN, O.; IZDRUI, D.; VICOVEANU, D. Brain Tumor Detection and Classification by MRI Using Biologically Inspired Orthogonal Wavelet Transform and Deep Learning Techniques. *Journal of Healthcare Engineering*, v. 2022, p. 1–18, January 2022. ISSN 2040-2309. Available at: <<http://www.ncbi.nlm.nih.gov/pubmed/35047149http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC8763556https://www.hindawi.com/journals/jhe/2022/2693621/>>. Cited on page 3.
- ARUMUGAM, M.; THIYAGARAJAN, A.; ADHI, L.; ALAGAR, S. Crossover smell agent optimized multilayer perceptron for precise brain tumor classification on mri images. *Expert Systems with Applications*, Elsevier, v. 238, p. 121453, 2024. Cited on page 2.
- BADŽA, M. M.; BARJAKTAROVIĆ, M. C. Classification of brain tumors from mri images using a convolutional neural network. *Applied Sciences (Switzerland)*, v. 10, n. 6, 2020. ISSN 20763417. Cited on page 57.
- BISWAS, A.; ISLAM, M. S. A Hybrid Deep CNN-SVM Approach for Brain Tumor Classification. *Journal of Information Systems Engineering and Business Intelligence*, v. 9, n. 1, p. 1–15, April 2023. ISSN 2443-2555. Available at: <<https://e-journal.unair.ac.id/JISEBI/article/view/38587>>. Cited 3 times on pages 56, 57, and 59.
- CASTILLO, M. History and evolution of brain tumor imaging: insights through radiology. *Radiology*, v. 273, n. 2 Suppl, p. S111–25, November 2014. ISSN 1527-1315. Available at: <<http://pubs.rsna.org/doi/10.1148/radiol.14140130http://www.ncbi.nlm.nih.gov/pubmed/25340432>>. Cited on page 7.
- CHENG, J. *brain tumor dataset*. 2017. Accessed 30 August 2023. Available at: <https://figshare.com/articles/dataset/brain_tumor_dataset/1512427>. Cited 8 times on pages vii, ix, 3, 15, 17, 27, 28, and 61.

- CHENG, J.; HUANG, W.; CAO, S.; YANG, R.; YANG, W.; YUN, Z.; WANG, Z.; FENG, Q. Enhanced Performance of Brain Tumor Classification via Tumor Region Augmentation and Partition. *PloS one*, v. 10, n. 10, October 2015. ISSN 1932-6203. Available at: <<https://dx.plos.org/10.1371/journal.pone.0140381><http://www.ncbi.nlm.nih.gov/pubmed/26447861><http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC4598126>>. Cited 6 times on pages vii, 27, 28, 56, 59, and 61.
- CHENG, J.; YANG, W.; HUANG, M.; HUANG, W.; JIANG, J.; ZHOU, Y.; YANG, R.; ZHAO, J.; FENG, Y.; FENG, Q.; CHEN, W. Retrieval of Brain Tumors by Adaptive Spatial Pooling and Fisher Vector Representation. *PloS one*, v. 11, n. 6, p. e0157112, June 2016. ISSN 1932-6203. Available at: <<https://dx.plos.org/10.1371/journal.pone.0157112><http://www.ncbi.nlm.nih.gov/pubmed/27273091><http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC4894628>>. Cited 4 times on pages 27, 56, 59, and 61.
- CHITTATHURU, D.; UN, N.; REDDY, P.; GADEKALLU, T.; IWENDI, C.; WEI, C.; XIN, Q. Identification of malnutrition and prediction of bmi from facial images using real-time image processing and machine learning. *IET Image Processing*, v. 16, 05 2021. Cited on page 24.
- DAI, X.; XU, Y.; SONG, H.; ZHENG, J. Using image-based machine learning and numerical simulation to predict pesticide inline mixing uniformity. *Journal of the Science of Food and Agriculture*, v. 103, n. 2, p. 705–719, 2023. Available at: <<https://onlinelibrary.wiley.com/doi/abs/10.1002/jsfa.12182>>. Cited on page 24.
- DEANGELIS, L. M. Brain Tumors. *Medical Progress N Engl J Med*, v. 114, n. 2, p. 114–123, 2001. Cited 3 times on pages 14, 15, and 16.
- DECHTER, R. *Learning while searching in constraint-satisfaction problems*. Thesis (Doctorate) — University of California, Computer Science Department, Cognitive Systems Laboratory, 1986. Online. Cited on page 21.
- DEEPAK, S.; AMEER, P. M. Brain tumor classification using deep CNN features via transfer learning. *Computers in Biology and Medicine*, Elsevier Ltd, v. 111, p. 103345, June 2019. ISSN 0010-4825. Available at: <<https://doi.org/10.1016/j.combiomed.2019.103345>>. Cited 3 times on pages 57, 59, and 61.
- DEEPAK, S.; AMEER, P. M. MSG-GAN Based Synthesis of Brain MRI with Meningioma for Data Augmentation. In *2020 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT)*. [s.n.], 2020. p. 1–6. Available at: <<https://doi.org/10.1109/CONECCT50063.2020.9198672>>. Cited on page 25.
- DICOM Standard. *History of DICOM*. 2023. <<https://www.dicomstandard.org/history>>. Accessed on 10 September 2025. Cited on page 17.
- DOMINGOS, P. A few useful things to know about machine learning. *Communications of the ACM*, v. 55, n. 10, p. 78–87, October 2012. ISSN 0001-0782. Available at: <<https://dl.acm.org/doi/10.1145/2347736.2347755>>. Cited 2 times on pages 18 and 19.
- DORFNER, F. J.; PATEL, J. B.; KALPATHY-CRAMER, J.; GERSTNER, E. R.; BRIDGE, C. P. *A review of deep learning for brain tumor analysis in MRI*. [S.l.]: Nature Research, 2025. Cited on page 2.

- DIÁZ-PERNAS, F. J.; MARTÍNEZ-ZARZUELA, M.; ANTÓN-RODRÍGUEZ, M.; GONZÁLEZ-ORTEGA, D. A Deep Learning Approach for Brain Tumor Classification and Segmentation Using a Multiscale Convolutional Neural Network. *Healthcare*, 2021. Cited on page 57.
- E., T.; SARULADHA, K. Design of FCSE-GAN for Dissection of Brain Tumour in MRI. In *2020 International Conference on Smart Technologies in Computing, Electrical and Electronics (ICSTCEE)*. [S.l.]: IEEE, 2020. p. 1–6. Cited on page 25.
- FARIA, E. G. C. d.; NASCIMENTO, F. A. O.; MIOSSO, C. J. *Sistema Inteligente para Classificação Automática de Imagens de Ressonância Magnética de Neoplasias Cerebrais utilizando Redes Neurais Convolucionais*. 2025. Patente de Programa de Computador. Registro BR512025005453-0, 28 out. 2025. Instituto Nacional da Propriedade Industrial (INPI). Cited on page 28.
- GE, C.; GU, I. Y. H.; JAKOLA, A. S.; YANG, J. Enlarged Training Dataset by Pairwise GANs for Molecular-Based Brain Tumor Classification. *IEEE Access*, v. 8, p. 22560–22570, 2020. Available at: <<https://doi.org/10.1109/ACCESS.2020.2969805>>. Cited on page 25.
- GEROVITCH, S. How the computer got its revenge on the soviet union. *Nautilus*, April 2015. Archived from the original on 22 September 2021. Retrieved 19 September 2021. Available at: <<https://nautil.us/issue/24/error/how-the-computer-got-its-revenge-on-the-soviet-union>>. Cited on page 20.
- GOODFELLOW, I. J.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016. <<http://www.deeplearningbook.org>>. Cited on page 21.
- GUMAEI, A.; HASSAN, M. M.; HASSAN, M. R.; ALELAIWI, A.; FORTINO, G. A Hybrid Feature Extraction Method With Regularized Extreme Learning Machine for Brain Tumor Classification. *IEEE Access*, IEEE, v. 7, n. c, p. 36266–36273, 2019. ISSN 2169-3536. Available at: <<https://ieeexplore.ieee.org/document/8664160/>>. Cited 2 times on pages 57 and 61.
- HAMGHALAM, M.; SIMPSON, A. L. Medical image synthesis via conditional GANs: Application to segmenting brain tumours. *Computers in Biology and Medicine*, Elsevier, v. 170, p. 107982, June 2024. Cited on page 25.
- HAN, C.; RUNDO, L.; ARAKI, R.; NAGANO, Y.; FURUKAWA, Y.; MAURI, G.; NAKAYAMA, H.; HAYASHI, H. Combining noise-to-image and image-to-image GANs: Brain MR image augmentation for tumor detection. *IEEE Access*, v. 7, p. 156966–156977, 2019. Available at: <<https://doi.org/10.1109/ACCESS.2019.2947606>>. Cited on page 25.
- HAQ, E. U.; JIANJUN, H.; LI, K.; HAQ, H. U.; ZHANG, T. An MRI-based deep learning approach for efficient classification of brain tumors. *Journal of Ambient Intelligence and Humanized Computing*, Springer Berlin Heidelberg, v. 14, n. 6, p. 6697–6718, June 2023. ISSN 1868-5137. Available at: <<https://doi.org/10.1007/s12652-021-03535-9>><https://link.springer.com/10.1007/s12652-021-03535-9>>. Cited 3 times on pages 56, 57, and 59.
- HASAN, K.; HOSSAIN, R. B.; HASAN, M. Convolutional Neural Networks for Automated Classification of Brain Tumors. *North American Academic Research*, September 2023. Cited on page 2.

- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2nd. ed. [S.l.]: Springer Science & Business Media, 2009. Cited on page 20.
- HOLMES, O. W. History of Brain Tumor Surgery – A Global and Indian Perspective. *Archives of Medicine and Health Sciences*, 2021. Cited 4 times on pages 7, 8, 9, and 11.
- HOSCH, W. L. machine learning - artificial intelligence. *Encyclopedia Britannica*, December 2022. Accessed 8 February 2023. Available at: <<https://www.britannica.com/technology/machine-learning>>. Cited on page 18.
- HOSSAIN, R.; IBRAHIM, R. B.; HASHIM, H. B. Automated Brain Tumor Detection Using Machine Learning: A Bibliometric Review. *World Neurosurgery*, Elsevier Inc., v. 175, p. 57–68, 2023. ISSN 18788769. Available at: <<https://doi.org/10.1016/j.wneu.2023.03.115>>. Cited on page 24.
- HOSSAIN, S.; CHAKRABARTY, A.; GADEKALLU, T. R.; ALAZAB, M.; PIRAN, M. J. Vision Transformers, Ensemble Model, and Transfer Learning Leveraging Explainable AI for Brain Tumor Detection and Classification. *IEEE Journal of Biomedical and Health Informatics*, IEEE, v. 28, n. 3, p. 1261–1272, 2024. ISSN 21682208. Cited on page 2.
- INCA. *Câncer do sistema nervoso central*. [S.l.], 2022. INCA - Instituto Nacional do Câncer. Câncer do sistema nervoso central. Available at: <<https://www.gov.br/inca/pt-br/assuntos/cancer/tipos/sistema-nervoso-central>>. Cited 4 times on pages 1, 7, 12, and 13.
- International Agency for Research on Cancer. *Global Cancer Observatory*. 2023. <<https://gco.iarc.fr/today/home>>. Accessed on 9 March 2023. Cited on page 12.
- JR, E. R. L.; KAYE, A. H. *Brain Tumors: An Encyclopedic Approach*. [S.l.]: Churchill Livingstone, 2002. Cited 2 times on pages 8 and 9.
- KARPAKAM, S.; KUMARESHAN, N. Enhanced brain tumor detection and classification using a deep image recognition generative adversarial network (DIR-GAN): a comparative study on MRI, X-ray, and Figshare datasets. *Neural Computing and Applications*, Springer London, v. 37, n. 14, p. 8731–8758, May 2025. ISSN 0941-0643. Available at: <<https://doi.org/10.1007/s00521-025-11031-whttps://link.springer.com/10.1007/s00521-025-11031-w>>. Cited 2 times on pages 58 and 59.
- KERR, P. B.; CAPUTY, A. J.; HORWITZ, N. H. A history of cerebral localization. *Neurosurgical focus*, v. 18, n. 4, p. e1, April 2005. ISSN 1092-0684. Available at: <<https://thejns.org/view/journals/neurosurg-focus/18/4/foc.2005.18.4.2.xmlhttp://www.ncbi.nlm.nih.gov/pubmed/15844861>>. Cited 2 times on pages 9 and 10.
- KHAN, M. A. An automated and fast system to identify covid-19 from x-ray radiograph of the chest using image processing and machine learning. *International Journal of Imaging Systems and Technology*, Wiley Online Library, v. 31, n. 2, p. 499–508, 2021. Available at: <<https://onlinelibrary.wiley.com/doi/abs/10.1002/ima.22564>>. Cited on page 24.
- KHAN, M. S. I.; RAHMAN, A.; DEBNATH, T.; KARIM, M. R.; NASIR, M. K.; BAND, S. S.; MOSAVI, A.; DEHZANGI, I. Accurate brain tumor detection using deep convolutional neural network. *Computational and Structural Biotechnology Journal*, The Author(s), v. 20, p. 4733–4745, 2022. ISSN 20010370. Available at: <<https://doi.org/10.1016/j.csbj.2022.08.039https://doi.org/10.1016/j.csbj.2022.08.039>>.

[//linkinghub.elsevier.com/retrieve/pii/S2001037022003737](https://linkinghub.elsevier.com/retrieve/pii/S2001037022003737)>. Cited 2 times on pages 3 and 24.

KOMORI, T. Updated 2016 WHO classification of tumors of the CNS: Turning the corner where molecule meets pathology. *Brain Tumor Pathology*, v. 34, p. 139–140, 2017. Cited on page 10.

KUMAR, T. Early Diagnosis of Brain Tumor Using AI and Mathematical Modeling. *INTERANTIONAL JOURNAL OF SCIENTIFIC RESEARCH IN ENGINEERING AND MANAGEMENT*, v. 09, p. 1–9, January 2025. ISSN 25823930. Available at: <<https://ijsrem.com/download/early-diagnosis-of-brain-tumor-using-ai-and-mathematical-modeling/>>. Cited on page 2.

LAKSHMI, K.; AMARAN, S.; SUBBULAKSHMI, G.; PADMINI, S.; JOSHI, G. P.; CHO, W. Explainable artificial intelligence with UNet based segmentation and Bayesian machine learning for classification of brain tumors using MRI images. *Scientific Reports*, Nature Research, v. 15, January 2025. ISSN 20452322. Cited on page 2.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, May 2015. ISSN 0028-0836. Available at: <<https://www.nature.com/articles/nature14539>>. Cited on page 21.

LEITE, C. d. C.; JUNIOR, E. A.; LUCATO, L. T. *Neurorradiologia: diagnóstico por imagem das alterações encefálicas*. [S.l.]: Guanabara Koogan, 2008. Cited 2 times on pages 16 and 17.

LINDSAY, R. P. The impact of automation on public administration. *Western Political Quarterly*, v. 17, n. 3, p. 78–81, 1964. ISSN 0043-4078. Archived from the original on 6 October 2021. Retrieved 6 October 2021. Cited on page 20.

LOUIS, D. N.; OHGAKI, H.; WIESTLER, O. D.; CAVENEE, W. K.; BURGER, P. C.; JOUVET, A.; SCHEITHAUER, B. W.; KLEIHUES, P. The 2007 WHO Classification of Tumours of the Central Nervous System. *Acta Neuropathologica*, v. 114, p. 97–109, 2007. ISSN 1432-0533. Cited on page 11.

LUGER, G. F. *Inteligência Artificial: Estruturas e Estratégias para a Solução de Problemas Complexos*. 4th. ed. Porto Alegre: Bookman, 2004. 774 p. ISBN 85-363-0396-4. Cited on page 19.

LUO, J.; PAN, M.; MO, K.; MAO, Y.; ZOU, D. Emerging role of artificial intelligence in diagnosis, classification and clinical management of glioma. *Seminars in Cancer Biology*, v. 91, p. 110–123, June 2023. ISSN 1044579X. Available at: <<http://www.ncbi.nlm.nih.gov/pubmed/36907387https://linkinghub.elsevier.com/retrieve/pii/S1044579X23000457>>. Cited on page 24.

MA, Y. Federated Learning for Brain Tumor Diagnosis: Methods, Challenges and Future Prospects. *ITM Web of Conferences*, v. 70, p. 03028, January 2025. ISSN 2271-2097. Available at: <<https://www.itm-conferences.org/10.1051/itmconf/20257003028>>. Cited on page 2.

MACEWEN, W. Intra-cranial lesions. In WILKINS, R. H. (Ed.). *Neurosurgical Classics*. New York: Johnson Reprint Corp., 1965. p. 374–375. Cited on page 9.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, v. 5, p. 115–137, 1943. Cited on page 19.

- MOHSEN, S.; ALI, A. M.; EL-RABAIE, E. S. M.; ELKASEER, A.; SCHOLZ, S. G.; HASSAN, A. M. A. Brain Tumor Classification Using Hybrid Single Image Super-Resolution Technique With ResNext101_32× 8d and VGG19 Pre-Trained Models. *IEEE Access*, IEEE, v. 11, p. 55582–55595, May 2023. ISSN 21693536. Cited 3 times on pages 25, 58, and 59.
- MONDAL, A.; SHRIVASTAVA, V. K. A novel Parametric Flatten-p Mish activation function based deep CNN model for brain tumor classification. *Computers in Biology and Medicine*, Elsevier Ltd, v. 150, p. 106183, November 2022. ISSN 18790534. Available at: <<https://doi.org/10.1016/j.compbio.2022.106183>>. Cited 3 times on pages 56, 59, and 61.
- MUGDHA, S. B. S.; UDDIN, M. Neurosight: A deep-learning integrated efficient approach to brain tumor detection. *Engineering Reports*, John Wiley and Sons Inc, v. 7, January 2025. ISSN 25778196. Cited on page 2.
- NAG, A.; MONDAL, H.; HASSAN, M. M.; AL-SHEHARI, T.; KADRIE, M.; AL-RAZGAN, M.; ALFAKIH, T.; BISWAS, S.; BAIRAGI, A. K. TumorGANet: A Transfer Learning and Generative Adversarial Network-based Data Augmentation Model for Brain Tumor Classification. *IEEE Access*, IEEE, v. 12, p. 103060–103081, May 2024. ISSN 21693536. Cited on page 2.
- NAYAK, D. R.; PADHY, N.; MALLICK, P. K.; SINGH, A. A deep autoencoder approach for detection of brain tumor images. *Computers and Electrical Engineering*, Elsevier Ltd, v. 102, p. 108238, 2022. ISSN 00457906. Available at: <<https://doi.org/10.1016/j.compeleceng.2022.108238><https://linkinghub.elsevier.com/retrieve/pii/S0045790622004748>>. Cited 2 times on pages 3 and 24.
- NEMA. *Digital Imaging and Communications in Medicine (DICOM)*. 2023. <https://dicom.nema.org/medical/dicom/current/output/chtml/part01/sect_1.3.html>. Accessed on 10 September 2025. Cited on page 17.
- NIA, N. G.; KAPLANOGLU, E.; NASAB, A. Evaluation of artificial intelligence techniques in disease diagnosis and prediction. *Discover Artificial Intelligence*, Springer International Publishing, v. 3, n. 1, p. 5, January 2023. ISSN 2731-0809. Available at: <<https://doi.org/10.1007/s44163-023-00049-5><https://link.springer.com/10.1007/s44163-023-00049-5>>. Cited 2 times on pages 21 and 24.
- NIH. *What is Cancer?* [S.l.], 2021. Available at: <<https://www.cancer.gov/about-cancer/understanding/what-is-cancer>>. Cited on page 11.
- NOREEN, N.; PALANIAPPAN, S.; QAYYUM, A.; AHMAD, I.; IMRAN, M.; SHOAIIB, M. A Deep Learning Model Based on Concatenation Approach for the Diagnosis of Brain Tumor. *IEEE Access*, IEEE, v. 8, p. 55135–55144, 2020. ISSN 21693536. Cited on page 61.
- OPENCV-TEAM. *OpenCV-Python: Open Source Computer Vision Library*. 2024. <<https://pypi.org/project/opencv-python/>>. Accessed on July 2025. Cited on page 29.
- OSBORN, A. G. *Encéfalo de Osborn: imagem, patologia e anatomia*. Porto Alegre: Artmed, 2014. Revisão técnica: Leonardo Modesti Vedolin. Cited 2 times on pages 15 and 17.
- PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.;

- VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011. Cited 2 times on pages vii and 34.
- PIZER, S. M.; ACKERMAN, L. V. Dicom: Digital imaging and communications in medicine. *Radiographics*, v. 16, n. 2, p. 345–346, 1996. Cited on page 17.
- PP, K.; KP, P. The Ancient Greek Discovery of the Nervous System: Alcmaeon, Praxagoras and Herophilus. *Journal of Neurology and Neuroscience*, v. 06, n. s1, p. 1–5, 2015. ISSN 21716625. Available at: <<http://www.jneuro.com/neurology-neuroscience/the-ancient-greek-discovery-of-the-nervous-systemalcmaeon-praxagoras-and-herophilus.php?aid=6917>>. Cited 2 times on pages 7 and 8.
- PREUL, M. C. History of brain tumor surgery. *Neurosurg Focus*, v. 18, n. 4, 2005. Cited 2 times on pages 9 and 11.
- REHMAN, A.; NAZ, S.; IMRAN, M.; AKRAM, F.; IMRAN, M. A Deep Learning-Based Framework for Automatic Brain Tumors Classification Using Transfer Learning. *Circuits, Systems, and Signal Processing*, Springer US, 2019. ISSN 1531-5878. Available at: <<https://doi.org/10.1007/s00034-019-01246-3>>. Cited 3 times on pages 57, 58, and 59.
- RUNGE, V. M.; SMOKER, W. R. K.; VALAVANIS, A. *Neuroradiology: The Essentials with MR and CT*. New York: Thieme Medical Publishers, 2015. ISBN 978-1-60406-916-7. Cited on page 15.
- RUSSELL, S. J.; NORVIG, P. *Artificial intelligence a modern approach*. [S.l.]: London, 2010. Cited on page 19.
- SACHDEVA, J.; SHARMA, D.; AHUJA, C. K. Comparative Analysis of Different Deep Convolutional Neural Network Architectures for Classification of Brain Tumor on Magnetic Resonance Images. *Archives of Computational Methods in Engineering*, Springer, v. 31, n. 4, p. 1959–1978, 2024. Cited on page 2.
- SAHOO, S.; MISHRA, S.; PANDA, B.; BHOI, A. K.; BARSOCCHI, P. An Augmented Modulated Deep Learning Based Intelligent Predictive Model for Brain Tumor Detection Using GAN Ensemble. *Sensors*, v. 23, n. 15, 2023. ISSN 1424-8220. Available at: <<https://www.mdpi.com/1424-8220/23/15/6930>>. Cited 2 times on pages 25 and 61.
- SAMUEL, A. L. Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, v. 3, n. 3, p. 210–229, 1959. Available at: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5392560>>. Cited on page 20.
- SCHULZ, M.-a.; YEO, B. T. T.; VOGELSTEIN, J. T.; MOURAO-MIRANADA, J.; KATHER, J. N.; KORDING, K.; RICHARDS, B.; BZDOK, D. Different scaling of linear models and deep learning in UKBiobank brain images versus machine-learning datasets. *Nature Communications*, Springer US, v. 11, n. 1, p. 4238, August 2020. ISSN 2041-1723. Available at: <<http://dx.doi.org/10.1038/s41467-020-18037-zhttps://www.nature.com/articles/s41467-020-18037-z>>. Cited 2 times on pages 3 and 24.
- SHALEV-SHWARTZ, S.; BEN-DAVID, S. *Understanding Machine Learning - From Theory to Algorithms*. [S.l.]: Cambridge University Press, 2014. I-XVI, 1-397 p. ISBN 978-1-10-705713-5. Cited on page 18.

- SHAMSHAD, N.; SARWR, D.; ALMOGREN, A.; SALEEM, K.; MUNAWAR, A.; Ur Rehman, A.; BHARANY, S. Enhancing Brain Tumor Classification by a Comprehensive Study on Transfer Learning Techniques and Model Efficiency Using MRI Datasets. *IEEE Access*, IEEE, v. 12, p. 1–1, June 2024. ISSN 21693536. Cited on page 2.
- SILLE, R.; CHOUDHURY, T.; SHARMA, A.; CHAUHAN, P.; TOMAR, R.; SHARMA, D. A novel generative adversarial network-based approach for automated brain tumour segmentation. *Medicina*, v. 59, n. 1, p. 119, 2023. Available at: <<https://doi.org/10.3390/medicina59010119>>. Cited on page 25.
- SOLANKI, S.; SINGH, U. P.; CHOUHAN, S. S.; JAIN, S. Brain tumor detection and classification using intelligence techniques: An overview. *IEEE Access*, v. 11, p. 12870–12886, 2023. Cited on page 24.
- SOMASUNDARAM, S.; GOBINATH, R. Current Trends on Deep Learning Models for Brain Tumor Segmentation and Detection - A Review. In COM-IT-CON. *Proceedings of the International Conference on Machine Learning, Big Data, Cloud and Parallel Computing: Trends, Perspectives and Prospects, COMITCon 2019*. India, 2019. p. 217–221. Cited on page 21.
- SWATI, Z. N. K.; ZHAO, Q.; KABIR, M.; ALI, F.; ALI, Z.; AHMED, S.; LU, J. Content-Based Brain Tumor Retrieval for MR Images Using Transfer Learning. *IEEE Access*, IEEE, v. 7, n. c, p. 17809–17822, 2019. ISSN 2169-3536. Available at: <<https://ieeexplore.ieee.org/document/8611216/>>. Cited 3 times on pages 57, 58, and 59.
- TALUKDER, M. A.; ISLAM, M. M.; UDDIN, M. A.; AKHTER, A.; PRAMANIK, M. A. J.; ARYAL, S.; ALMOYAD, M. A. A.; HASAN, K. F.; MONI, M. A. An efficient deep learning model to categorize brain tumor using reconstruction and fine-tuning. *Expert Systems with Applications*, Elsevier Ltd, v. 230, p. 120534, May 2023. ISSN 09574174. Available at: <<https://doi.org/10.1016/j.eswa.2023.120534><http://arxiv.org/abs/2305.12844><https://linkinghub.elsevier.com/retrieve/pii/S0957417423010369>>. Cited 3 times on pages 56, 57, and 59.
- TANDEL, G. S.; BISWAS, M.; KAKDE, O. G.; TIWARI, A.; SURI, H. S.; TURK, M.; LAIRD, J. R.; ASARE, C. K.; ANKRAH, A. A.; KHANNA, N. N.; MADHUSUDHAN, B. K.; SABA, L.; SURI, J. S. A Review on a Deep Learning Perspective in Brain Cancer Classification. *Cancers*, v. 11, n. 1, 2019. ISSN 2072-6694. Available at: <<https://www.mdpi.com/2072-6694/11/1/111>>. Cited 4 times on pages 2, 3, 16, and 24.
- UCSF - University of California, San Francisco. *Imaging Data 101: Introduction to DICOM*. 2024. <<https://radiology.ucsf.edu/research/core-services/imaging-data-101>>. Accessed on 10 September 2025. Cited on page 17.
- VAIYAPURI, T.; JAIGANESH, M.; AHMAD, S.; ABDELJABER, H. A.; YANG, E.; JEONG, S. yong. Ensemble Learning Driven Computer-Aided Diagnosis Model for Brain Tumor Classification on Magnetic Resonance Imaging. *IEEE Access*, IEEE, v. 11, p. 91398–91406, August 2023. ISSN 21693536. Cited on page 57.
- VURE, R. B.; PAPPALA, L. K. Enhanced brain tumor classification framework using deep learning. *Scientific Reports*, v. 15, n. 1, p. 35814, 2025. ISSN 2045-2322. Available at: <<https://doi.org/10.1038/s41598-025-19882-y>>. Cited 2 times on pages 58 and 59.

- WAGEH, M.; AMIN, K.; ALGARNI, A. D.; HAMAD, A. M.; IBRAHIM, M. Brain Tumor Detection Based on Deep Features Concatenation and Machine Learning Classifiers with Genetic Selection. *IEEE Access*, August 2024. ISSN 21693536. Cited on page 2.
- WANG, G.; JACOB, M.; MOU, X.; SHI, Y.; ELDAR, Y. C. Deep tomographic image reconstruction: Yesterday, today, and tomorrow—editorial for the 2nd special issue “machine learning for image reconstruction”. *IEEE Transactions on Medical Imaging*, v. 40, n. 11, p. 2956–2964, 2021. Cited on page 24.
- WERNICK, M. N.; YANG, Y.; BRANKOV, J. G.; YOURGANOV, G.; STROTHER, S. C. Machine Learning in Medical Imaging. *IEEE SIGNAL PROCESSING MAGAZINE*, July 2010. Cited 2 times on pages 18 and 19.
- YANG, W. L.; SU, X. R.; LI, S.; ZHAO, K. Y.; YUE, Q. Utilizing machine-learning techniques on mri radiomics to identify primary tumors in brain metastases. *Frontiers in Neurology*, Frontiers Media SA, v. 15, 2024. ISSN 16642295. Cited on page 2.
- ZHANG, W. J.; CHEN, W. T.; LIU, C. H.; CHEN, S. W.; LAI, Y. H.; YOU, S. D. Feasibility Study of Detecting and Segmenting Small Brain Tumors in a Small MRI Dataset with Self-Supervised Learning. *Diagnostics*, Multidisciplinary Digital Publishing Institute (MDPI), v. 15, February 2025. ISSN 20754418. Cited on page 2.
- ZHOU, Z.; MA, A.; FENG, Q.; WANG, R.; CHENG, L.; CHEN, X.; YANG, X.; LIAO, K.; MIAO, Y.; QIU, Y. Super-resolution of brain tumor mri images based on deep learning. *Journal of Applied Clinical Medical Physics*, Wiley, v. 23, n. 11, p. 1–13, 2022. Cited on page 25.
- ZULFIQAR, F.; Ijaz Bajwa, U.; MEHMOOD, Y. Multi-class classification of brain tumor types from MR images using EfficientNets. *Biomedical Signal Processing and Control*, Elsevier Ltd, v. 84, p. 104777, March 2023. Available at: <<https://doi.org/10.1016/j.bspc.2023.104777><https://linkinghub.elsevier.com/retrieve/pii/S1746809423002100>>. Cited 3 times on pages 56, 57, and 59.

.1 APPENDIX A

Portuguese version of this dissertation starting from the next page.

Portuguese title:

"Inteligência Artificial Aplicada ao Diagnóstico de Neoplasias Cerebrais"



INTELIGÊNCIA ARTIFICIAL APLICADA AO DIAGNÓSTICO DE NEOPLASIAS CEREBRAIS

EDILAINE GONÇALVES COSTA DE FARIA

Orientadores: Francisco Assis de Oliveira Nascimento, Phd (UnB)
e Cristiano Jacques Miosso, Phd (UnB)

**MONOGRAFIA DO EXAME DE DEFESA DE DOUTORADO
EM ENGENHARIA ELÉTRICA**

**DEPARTAMENTO DE ENGENHARIA ELÉTRICA
FACULDADE DE TECNOLOGIA**

UNIVERSIDADE DE BRASÍLIA

Universidade de Brasília
Faculdade de Tecnologia
Departamento de Engenharia Elétrica

Inteligência Artificial Aplicada ao Diagnóstico de Neoplasias
Cerebrais

Edilaine Gonçalves Costa de Faria

MONOGRAFIA DO EXAME DE DEFESA DE DOUTORADO SUBMETIDA
AO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA DA
UNIVERSIDADE DE BRASÍLIA COMO PARTE DOS REQUISITOS NECES-
SÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR.

APROVADA POR:

Francisco Assis de Oliveira Nascimento, Phd (UnB)
(Orientador)

Fábio Henrique Monteiro Oliveira, Phd (IFB)
(Examinador Externo)

André Coutinho Castilla, Phd
(Examinador Externo)

Adson Ferreira da Rocha, Phd (UnB)
(Examinador Interno)

Brasília/DF, Fevereiro de 2026.

FICHA CATALOGRÁFICA

FARIA, EDILAINÉ GONÇALVES COSTA DE

Inteligência Artificial Aplicada ao Diagnóstico de Neoplasias Cerebrais. [Brasília/DF] 2026. PPGEE 218/25, 95p., 210 x 297 mm (ENE/FT/UnB, Doutor, Monografia do Exame de Defesa de Doutorado, 2026).

Universidade de Brasília, Faculdade de Tecnologia, Departamento de Engenharia Elétrica.

Departamento de Engenharia Elétrica

- | | |
|----------------------------|------------------------------------|
| 1. Neoplasias cerebrais | 2. Imagem de Ressonância Magnética |
| 3. Aprendizagem de Máquina | 4. Aprendizagem profunda |
| 5. Aumento de dados | 6. Transferência de Conhecimento |
| I. ENE/FT/UnB | II. Título (série) |

REFERÊNCIA BIBLIOGRÁFICA

FARIA, EDILAINÉ GONÇALVES COSTA DE (2026). Inteligência Artificial Aplicada ao Diagnóstico de Neoplasias Cerebrais. Monografia do Exame de Defesa de Doutorado, Publicação PPGEE 218/25, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, 95p.

CESSÃO DE DIREITOS

AUTOR: Edilaine Gonçalves Costa de Faria

TÍTULO: Inteligência Artificial Aplicada ao Diagnóstico de Neoplasias Cerebrais.

GRAU: Doutor ANO: 2026

É concedida à Universidade de Brasília permissão para reproduzir cópias desta Monografia do Exame de Defesa de Doutorado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta Monografia do Exame de Defesa de Doutorado pode ser reproduzida sem autorização por escrito do autor.

Edilaine Gonçalves Costa de Faria

Universidade de Brasília (UnB)

Campus Darcy Ribeiro

Faculdade de Tecnologia - FT

Departamento de Engenharia Elétrica(ENE)

Brasília - DF CEP 70919-970

AGRADECIMENTOS

Agradeço, primeiramente, a Deus, por me conceder força e sabedoria ao longo do desenvolvimento deste trabalho.

Agradeço à minha família, especialmente à minha mãe, ao meu pai, à minha irmã e à minha sobrinha, pelo incentivo e apoio. Agradeço também aos amigos e aos profissionais de saúde que estiveram ao meu lado, oferecendo suporte e compreensão durante o período do doutorado.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de estudos por meio do Programa de Demanda Social.

Agradeço aos professores Francisco Assis e Cristiano Jacques Miosso pelas orientações e contribuições. Acrescento também o agradecimento aos demais docentes da Universidade de Brasília (UnB) pelo conhecimento compartilhado ao longo do curso.

Agradeço aos colegas e professores que colaboraram no desenvolvimento deste trabalho, em especial aos integrantes do Grupo de Aprendizado de Máquina (Machine Learning Group – MLG).

Por fim, agradeço aos membros da banca examinadora pela disponibilidade, pelas sugestões e pelas contribuições que enriqueceram esta pesquisa.

ABSTRACT

The medical evaluation of Magnetic Resonance Imaging (MRI) is aimed at preventing possible complications caused by brain neoplasms, and this diagnostic method has become increasingly optimized due to technological advances. Therefore, with these advances and the objective of automating this procedure to assist physicians, this work focused on investigating the development of algorithms to support the diagnosis of brain neoplasms. In this study, it is investigated whether the performance metrics of the developed system are capable of identifying three different types of brain neoplasms in MRI images, namely, meningioma, glioma, and pituitary adenomas, with values superior to those reported in the scientific literature, considering the lowest possible computational cost.

Several solutions based on training are reported in the literature, yet relatively few studies systematically compare their performance in scenarios involving smaller datasets, considering models of varying complexity and distinct data augmentation techniques. Hence, this study investigates the development of an MRI brain neoplasm classification system, including scenarios in which the amount of data is smaller than that commonly reported in the literature. The different deep learning strategies explored were data augmentation with traditional and pretrained models; feature extraction followed by classification; and transfer learning in restricted data scenarios, as well as using Generative Adversarial Networks for generating training images.

The obtained results were comparable to those reported in the literature. The network trained with augmented data, using flip and noise transformations and only the axial slice, developed from a pretrained architecture, achieved an accuracy of 88.4%, precision of 84.3%, recall of 84.9%, and F-score of 84.6%. Deep learning models employing transfer learning achieved superior results, reaching an accuracy of up to 96.8%; in this case, precision reached 96.8%, recall 94.8%, and F-measure 95.6%, using DenseNet121. Consequently, the employed strategies are efficient for this application in supporting the diagnosis of brain neoplasms.

The models trained with images generated by a Generative Adversarial Network did not

achieve results superior to those obtained with real images. Nevertheless, the results are expressive according to the literature, indicating that such synthetic image generation can be applied in studies involving brain neoplasm classification systems. Therefore, further exploration of this approach in MRI image analysis is one of the proposed directions for future work. In addition, another possible line of future research would be to analyze the complexity of the proposed strategies, including processing requirements and energy consumption, which would be valuable for the development of embedded systems.

In summary, among the strategies evaluated in this study, transfer learning proved to be the most effective, because its generalizability and the stability of the obtained results ensure superior performance across all evaluated metrics. This demonstrates that such an approach can extract relevant features even in a scenario involving only axial slice images. Hence, this study confirms the effectiveness of advanced deep learning architectures in supporting automated image-based diagnosis, even when dealing with limited datasets. Therefore, there has been a significant advancement in supporting the diagnosis of brain neoplasms, contributing to faster and more accurate clinical decisions, which may also be achieved through incidental findings. Furthermore, such strategies can also be applied to other types of brain imaging diagnoses.

Keywords: Brain Neoplasms, Magnetic Resonance Imaging, Feature Extraction, Classification, Machine Learning, Deep Learning, Transfer Learning, Generative Adversarial Network.

RESUMO

Título: Inteligência Artificial Aplicada ao Diagnóstico de Neoplasias Cerebrais

A avaliação médica de Imagens de Ressonância Magnética, do inglês - *Magnetic Resonance Imaging (MRI)*, para evitar possíveis complicações geradas por neoplasias cerebrais, é um dos métodos de diagnóstico e que se tornou mais otimizado devido aos avanços tecnológicos. Portanto, com esses avanços e o objetivo de automatizar esse procedimento para auxiliar os médicos, este trabalho concentrou-se em investigar o desenvolvimento de algoritmos para auxiliar no diagnóstico de neoplasias cerebrais. Neste estudo, é investigado se medidas de desempenho de um sistema desenvolvido é capaz de identificar três tipos diferentes de neoplasias cerebrais de MRI, sendo meningioma, glioma e adenomas de hipófise, com valores superiores aos apresentados na literatura científica, considerando o menor custo computacional possível.

Diversas soluções baseadas em treinamento existem na literatura, mas há relativamente poucos estudos comparando, de forma sistemática, o desempenho em cenários com bases menores, levando em conta modelos de diferentes complexidade e diferentes técnicas de aumento de dados. Diante disto, este estudo consiste em investigar o desenvolvimento de um sistema classificador de MRI de neoplasias cerebrais, inclusive em situações em que o número de dados é relativamente menor em comparação com as quantidades de dados apresentadas na literatura. Logo, neste estudo, foram utilizadas diferentes estratégias de aprendizagem profunda, tais como aumento de dados com modelos tradicionais e pré-treinados, extração de características seguida da classificação e transferência de conhecimento em cenários com números restritos de dados, além de uso de Rede Adversária Generativa para geração de imagens de treinamento.

Os resultados obtidos ficaram próximos aos resultados da literatura. A rede com aumento de dados, utilizando flip e ruído e utilizando apenas o corte axial, desenvolvida a partir de uma arquitetura pré-treinada, alcançou o resultado com acurácia de 88,4%; precisão de 84,3%; *recall* de 84,9%; e f-score de 84,6%. O uso de aprendizado profundo em modelos de transferência de conhecimento proporcionou melhores resultados, com uma acurácia de até 96,8%, neste caso a precisão resultou em 96,8%, *recall* em 94,8% e medida-F em 95,6%, utilizando Densenet 121.

Logo, como resultado, determinou-se que as estratégias empregadas são eficientes para esta aplicação de auxílio a diagnóstico de neoplasias cerebrais.

Além disso, com imagens geradas por Rede Adversária Generativa para o treinamento das redes não foram alcançados resultados superiores aos obtidos com imagens reais. Apesar disso, os resultados são expressivos, segundo a literatura, indicando que é possível utilizar esse tipo de geração de imagens em estudos sobre sistema classificador de neoplasias cerebrais. Logo, o aprofundamento deste tipo de aplicação em MRI é uma das propostas de trabalho futuro. Além disso, outro possível trabalho futuro, seria analisar a complexidade das estratégias, processamento e consumo de energia, sendo útil no desenvolvimento de sistemas embarcados.

Em síntese, dentre as estratégias avaliadas neste estudo, transferência de conhecimento mostrou-se a mais eficiente, destacando-se sobretudo pela capacidade de generalização e pela estabilidade dos resultados obtidos, garantindo desempenho superior em todas as métricas avaliadas, evidenciando que essa abordagem é capaz de extrair características relevantes mesmo em um cenário de imagens apenas do corte axial. Portanto, este trabalho confirma a efetividade do uso de arquiteturas avançadas de aprendizagem profunda para o auxílio a diagnóstico por imagem automatizado, inclusive em situações de quantidades restritas de imagens. Logo, houve um avanço significativo no suporte ao diagnóstico de neoplasias cerebrais, contribuindo para decisões clínicas mais rápidas, precisas e, também, podendo ser obtidas por meio de um achado incidental. Além disso, tais estratégias podem, inclusive, ser aplicadas em outros tipos de diagnósticos de imagens cerebrais.

Palavras-chave: Neoplasias Cerebrais, Imagem de Ressonância Magnética, Extração de Características, Classificação, Aprendizado de Máquina, Aprendizado Profundo, Transferência de Conhecimento, Rede Adversária Generativa.

SUMÁRIO

Lista de figuras	iii
Lista de tabelas	vii
Glossário	x
Capítulo 1 – Introdução	1
1.1 Contextualização	1
1.2 Definições do problema científico e proposta	3
1.3 Objetivos	5
1.3.1 Objetivo Geral	5
1.3.2 Objetivos específicos	5
1.4 Justificativa e contribuições	6
Capítulo 2 – Fundamentação teórica	8
2.1 Fundamentação Médico-Científica	8
2.1.1 Evolução histórica das neoplasias cerebrais	8
2.1.2 Epidemiologia global de neoplasias no Sistema Nervoso Central	13
2.1.3 Tipos de Neoplasias Cerebrais	14
2.1.4 Modalidades de aquisição de imagens médicas	17
2.2 Inteligência Artificial	19
2.2.1 Fatores históricos da evolução da Inteligência Artificial	20
2.2.2 Exemplos de Classificadores	23
2.2.3 Algumas aplicações de Aprendizagem de Máquina na literatura	25
2.2.4 Rede Adversária Generativa	26
Capítulo 3 – Materiais e Métodos	28
3.1 Banco de dados	28
3.1.1 Figshare - 3 Classes	28
3.2 CNN utilizando aumento de dados - Estratégia 1	31
3.2.1 Todos os três cortes	32

3.2.2	Apenas corte axial	33
3.3	Extração de características utilizando Redes Neurais Convolucionais - Estratégia 2	33
3.4	Transferência de conhecimento - Estratégia 3	36
3.5	Rede Adversária Generativa	37
3.6	Métricas utilizadas na avaliação de desempenho	39
Capítulo 4 – Resultados e Discussão		43
4.1	Técnicas de aumento de dados - Estratégia 1	43
4.2	Classificação de características relacionadas a extração utilizando CNN (apenas corte Axial) - Estratégia 2	49
4.3	Transferência de Conhecimento (apenas corte axial) - Estratégia 3	52
4.4	Rede Adversária Generativa	57
4.5	Pesquisas científicas abordadas no Estado da Arte	59
4.6	Discussões gerais dos resultados	61
Capítulo 5 – Conclusão		65
Referências		66

LISTA DE FIGURAS

2.1	Quantidades de mortes relacionadas a tumores do sistema nervoso central (CNS) no Brasil em 2020 e 2022.	14
2.2	Exemplos de imagens de neoplasias cerebrais: Esquerda - Meningioma, Meio - Glioma, Direita - adenomas de hipófise	16
2.3	Exemplos dos três cortes de MRI de diferentes pacientes (à esquerda: sagital, meio: axial, direita: coronal).	18
3.1	Diagrama de blocos das camadas convolucionais da rede CNN utilizando imagens dos três cortes. Esta rede é composta por três sequências de camadas convolucionais, <i>maxpooling</i> e <i>dropout</i> , além de uma camada <i>flatten</i> , <i>dense</i> , <i>dropout</i> e <i>dense</i> , respectivamente.	32
3.2	Diagrama de blocos das etapas das camadas convolucionais da rede CNN pré-treinada (VGG16) utilizando imagens dos três diferentes cortes. Esta rede é composta por uma sequência de camadas convolucionais, <i>batch normalization</i> , <i>maxpooling</i> , <i>global average pooling</i> , <i>dropout</i> e <i>dense</i> , respectivamente.	33
3.3	Diagrama de blocos das camadas convolucionais no modelo CNN utilizando apenas cortes axiais. Esta rede é composta por três sequências de camadas convolucionais e <i>maxpooling</i> , além de uma camada <i>global average pooling</i> , <i>dense</i> , <i>dropout</i> e <i>dense</i> , respectivamente.	34
3.4	Diagrama de blocos das camadas convolucionais no modelo da rede CNN pré-treinada (VGG16) utilizando apenas cortes axiais. Esta rede é composta por uma sequência de <i>global average</i> , <i>dropout</i> e <i>dense</i> , respectivamente.	35

3.5	Diagrama de blocos das camadas convolucionais no modelo de <i>transfer learning</i> da CNN utilizando apenas cortes axiais. Esta rede é composta por camada <i>global average pooling</i> , duas sequências de <i>dense</i> , <i>batch normalization</i> e <i>dropout</i> , além de uma camada <i>dense</i> , respectivamente.	36
3.6	Diagrama de blocos das camadas convolucionais no modelo do gerador da GAN utilizada (camadas <i>Dense</i> , <i>BatchNormalization</i> , <i>LeakyReLU</i> , <i>Reshape</i> e múltiplas camadas <i>Conv2DTranspose</i> e <i>Conv2DTranspose</i>).	38
3.7	Diagrama de blocos das camadas convolucionais no modelo do discriminador da GAN utilizada (camadas <i>Conv2D</i> , <i>LeakyReLU</i> , <i>Dropout</i> , <i>Flatten</i> e <i>Dense</i>).	38
3.8	Diagrama da função desenvolvida para cálculo de V_P , F_P e F_n	40
4.1	Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN utilizando imagens de todos os cortes, sem aumento de dados. Em ‘(a)’ está a acurácia em função da época e em ‘(b)’ está a função de perda em função da época.	43
4.2	Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN pré-treinada utilizando imagens de todos os cortes, sem aumento de dados. Em ‘(a)’ está a acurácia em função da época e em ‘(b)’ está a função de perda em função da época.	45
4.3	Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN utilizando apenas o corte axial, sem aumento de dados. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época.	45
4.4	Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN utilizando apenas o corte axial, com aumento de dados utilizando flip. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época.	46
4.5	Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN utilizando apenas o corte axial, com aumento de dados utilizando flip e ruído. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época.	46

- 4.6 Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN pré-treinada utilizando apenas o corte axial, sem aumento de dados. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época. 47
- 4.7 Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN pré-treinada utilizando apenas o corte axial, com aumento de dados utilizando flip. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época. 47
- 4.8 Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN pré-treinada utilizando apenas o corte axial, com aumento de dados utilizando flip e ruído. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época. 48
- 4.9 Resultados de treinamento e validação obtidos por transferência de conhecimento utilizando DenseNet121 e apenas o corte axial. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época. 53
- 4.10 Matriz de confusão obtida para o modelo DenseNet121, utilizando transferência de conhecimento, em porcentagem (%). Corte axial de três classes distintas, meningioma, glioma e adenomas de hipófise, respectivamente. 54
- 4.11 Resultados de treinamento e validação obtidos por transferência de conhecimento utilizando MobileNet e apenas o corte axial. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época. 55
- 4.12 Resultados de treinamento e validação obtidos por transferência de conhecimento utilizando EfficientNetV2 B0 e apenas o corte axial. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época. 55
- 4.13 Resultados de treinamento e validação obtidos utilizando transferência de conhecimento com Inception V3 e apenas o corte axial. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época. 56

-
- 4.14 Resultados de treinamento e validação obtidos por transferência de conhecimento utilizando Xception e apenas o corte axial. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época. 56
- 4.15 Gráfico do resultado obtido da geração de imagens utilizando Rede Adversária Generativa da perda em função da época. 57
- 4.16 Exemplos das três classes de MRI geradas por GAN de diferentes pacientes (à esquerda: Meningioma, meio: Glioma, direita: Adenomas de Hipófise). 58
- 4.17 Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN pré-treinada utilizando apenas o corte axial. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época. 59

LISTA DE TABELAS

3.1	Características do banco de dados (CHENG, 2017) referenciadas em (CHENG <i>et al.</i> , 2015).	29
3.2	Quantidade de características (que foram divididas em treinamento e teste) extraídas por cada arquitetura de aprendizado profundo.	34
3.3	Classificadores e seus parâmetros utilizados neste trabalho na Estratégia 2. Todos do pacote da scikit-learn (PEDREGOSA <i>et al.</i> , 2011).	35
3.4	Quantidade de imagens de teste de cada classe, sendo, classe 1 para tumor do tipo meningioma, 2 para glioma, 3 para adenomas de hipófise. Aproximadamente, 80% para treinamento (desses, 20% foi separado para validação) e 20% para teste de cada corte (axial, sagital e coronal). Estratégia 3.	37
3.5	Quantidade de imagens de teste de cada classe, sendo, classe 1 para tumor do tipo meningioma, 2 para glioma, 3 para adenomas de hipófise. Aproximadamente, 80% para treinamento (desses, 10% foi separado para validação) e 20% para teste. Estratégia 3.	37
3.6	Quantidade de imagens de teste, treinamento e validação de cada classe, sendo, classe 1 para meningioma, 2 para glioma, 3 para adenomas de hipófise para a abordagem da GAN. Das imagens geradas pela GAN, 20% foram utilizadas para validação e 80% para treinamento.	39
4.1	Métricas de desempenho da classificação de neoplasias cerebrais a partir de MRI utilizando CNNs customizada e com redes pré-treinadas, inserindo em alguns casos o aumento de dados, além disso, com todos os cortes e também com apenas o corte axial.	44

4.2	Métricas de desempenho médias para classificações utilizando DenseNet121 para extrair as características. Classificação sem redução de dimensão. Tempo total de execução (treinamento e teste): 4 minutos e 6 segundos.	50
4.3	Métricas de desempenho médias para classificações utilizando DenseNet121 para extrair as características. Classificação com redução de dimensão. Tempo total de execução (treinamento e teste): 1 minuto e 14 segundos.	50
4.4	Métricas de desempenho médias para classificações utilizando MobileNet para extrair as características. Classificação com redução de dimensão.	50
4.5	Métricas de desempenho médias para classificações utilizando EfficientNet V2 B0 para extrair as características. Classificação com redução de dimensão.	51
4.6	Métricas de desempenho médias para classificações utilizando Inception V3 para extrair as características. Classificação com redução de dimensão.	51
4.7	Comparação de desempenho médio dos classificadores utilizando Xception para extrair as características. Classificação sem redução de dimensão. Tempo de execução de cada classificador em segundos. Tempo total de execução (treinamento e teste): 7 minutos e 12 segundos.	51
4.8	Comparação de desempenho médio dos classificadores utilizando Xception para extrair as características. Classificação com redução de dimensão. Tempo de execução de cada classificador em segundos. Tempo total de execução (treinamento e teste): 1 minuto e 19 segundos.	52
4.9	Métricas de desempenho da classificação de neoplasias cerebrais (glioma, meningioma e adenomas de hipófise) em MRI utilizando transferência de conhecimento (DenseNet121) em cada corte separadamente (axial, sagital, coronal).	52
4.10	Métricas de desempenho da classificação de neoplasias cerebrais (glioma, meningioma e adenomas de hipófise) em MRI utilizando transferência de conhecimento.	53
4.11	Métricas de desempenho da classificação de neoplasias cerebrais (glioma, meningioma e adenomas de hipófise) em MRI utilizando imagens geradas por Rede Adversária Generativa em estratégia utilizando redes pré-treinadas (Seção 4.1).	58

4.12 Pesquisas utilizando o conjunto de dados (CHENG, 2017) para a classificação por ressonância magnética de três doenças (meningioma, glioma e adenomas de hipófise) - apresentando a melhor acurácia média (%) e o tipo de modelos utilizados.	64
---	----

GLOSSÁRIO

AI	Inteligência Artificial - do inglês, <i>Artificial Intelligence</i>
ANN	Redes Neurais Artificiais - do inglês, <i>Artificial Neural Networks</i>
Bagg	<i>Bagging Classifier</i>
CNN	Rede Neural Convolutacional - do inglês, <i>Convolutional Neural Network</i>
CNS	Sistema Nervoso Central - do inglês, <i>Central Nervous System</i>
CT	Tomografia Computadorizada - do inglês, <i>Computed Tomography</i>
DC-ELM	<i>Deep Intense Normal Machine Learning</i>
DICOM	<i>Digital Imaging and Communications in Medicine</i>
DL	Aprendizado Profundo - do inglês, <i>Deep Learning</i>
DBM	Máquina Boltzmann Profunda - do inglês, <i>Deep Boltzmann Machine</i>
DBN	<i>Deep Belief Network</i>
DNN	Rede Neural Profunda - do inglês, <i>Deep Neural Network</i>
DT	Árvore de Decisão - do inglês, <i>Decision Tree Classifier</i>
ET	Árvores Extras - do inglês, <i>Extra Trees Classifier</i>
GAN	Redes Neurais Adversariais - do inglês, <i>Generative Adversarial Network</i>
GNB	Naive Bayes Gaussiano - do inglês, <i>Gaussian Naive Bayes</i>
INCA	Instituto Nacional de Câncer - do inglês, <i>National Cancer Institute</i>
INPI	Instituto Nacional da Propriedade Industrial
KNN	K Vizinhos Mais Próximos - do inglês, <i>K Neighbors Classifier</i>
ML	Aprendizado de Máquina - do inglês, <i>Machine Learning</i>

MLP	Perceptron de Múltiplas Camadas - do inglês, <i>Multi-layer Perceptron</i>
MRI	Imagem por Ressonância Magnética - do inglês, <i>Magnetic Resonance Imaging</i>
QDA	Análise Discriminante Quadrática - do inglês, <i>Quadratic Discriminant Analysis</i>
RF	Floresta Aleatória - do inglês, <i>Random Forest Classifier</i>
RGB	Vermelho, Verde e Azul, do inglês, <i>Red, Green and Blue</i>
RL	Aprendizado por Reforço - do inglês, <i>Reinforcement Learning</i>
RNN	Redes Neurais Recorrentes - do inglês, <i>Recurrent Neural Networks</i>
SGDC	Gradiente Descendente Estocástico - do inglês, <i>Stochastic Gradient Descent Classifier</i>
SVM	Máquinas de Vetores de Suporte - do inglês, <i>Support Vector Machine</i>

1.1 CONTEXTUALIZAÇÃO

Com avanços da Inteligência Artificial, do inglês *Artificial Intelligence (AI)*, aplicada à automatização, este trabalho concentrou-se em investigar o desenvolvimento de algoritmos para auxiliar no diagnóstico de neoplasias cerebrais. Neoplasias cerebrais consistem em proliferações anormais e descontroladas de células no tecido cerebral, podendo ser benignas ou malignas; no segundo caso, corresponde ao câncer. Este estudo é relevante, pois permite classificação sem a participação do especialista durante um processo de triagem, em que os casos graves podem ser encaminhados para decisão dos especialistas. Isto é utilizado em estudos baseados em técnicas de aprendizagem de máquina aplicadas a Imagens de Ressonância Magnética, do inglês - *Magnetic Resonance Imaging (MRI)* que consistem em automatizar o procedimento de diagnóstico.

No passado, as neoplasias cerebrais (exemplos estão na Figura 2.2) eram pouco compreendidas e frequentemente associadas a causas misteriosas ou espirituais. Devido à falta de tecnologia na época, cirurgias para remover neoplasias cerebrais eram raras e arriscadas. Posteriormente, com o advento da tecnologia na medicina moderna, as técnicas para detectar e remover neoplasias cerebrais foram aprimoradas. Chegando atualmente a análises de MRI, incluindo estratégias de detecção automatizadas utilizando AI.

De acordo com o Instituto Nacional do Câncer (INCA), as neoplasias no Sistema Nervoso Central (SNC) representam aproximadamente 1,4% a 1,8% dos tumores malignos em todo o mundo (INCA, 2022). Essas porcentagens ressaltam o impacto na saúde global dessa doença e a necessidade de detecção em estágios iniciais, quando for possível. Além disso, devido sua natureza potencialmente fatal, o diagnóstico precoce desempenha um papel crucial no tratamento eficaz de neoplasia cerebral, ajudando a prevenir e reduzir os casos de pessoas com

essa enfermidade.

Existem dois tipos de estratégias para detecção de neoplasias cerebrais, tais como, métodos invasivos e métodos não invasivos. O primeiro consiste em uma biópsia, já o segundo inclui exames de imagens, como a Tomografia Computadorizada (TC) e a Ressonância Magnética (RM) (TANDEL *et al.*, 2019). Sendo relevante o uso de estratégias rápidas e eficientes para diagnóstico precoce, com intuito de prevenir o avanço da doença e as consequências causadas por esta enfermidade.

Diversos estudos, inclusive recentes, apresentam este tipo de análise (DORFNER *et al.*, 2025; MA, 2025; KUMAR, 2025; ZHANG *et al.*, 2025; YANG *et al.*, 2024; LAKSHMI *et al.*, 2025; MUGDHA; UDDIN, 2025). Além disso, um exemplo é um estudo que revisa a arquitetura de Redes Neurais Convolucionais - do inglês, *Convolutional Neural Network (CNN)*, para a classificação de imagens e concentra-se no estudo de dados importantes para a análise de neoplasias cerebrais por meio de MRI (HASAN *et al.*, 2023). Adicionalmente, outro estudo envolve a comparação de diferentes arquiteturas de aprendizado profundo no estado da arte (ANAGUN, 2023). Além de estudos que avaliam o uso de transferência do conhecimento no mesmo tipo de aplicação (SACHDEVA *et al.*, 2024; ALBALAWI *et al.*, 2024). Outra pesquisa estuda a detecção de meningioma em neoplasias cerebrais (ANITA; KUMARAN, 2022), enquanto que, outro trabalho avaliou o caso de tumor e não tumor (ARUMUGAM *et al.*, 2024).

Além disso, redes de transferência de conhecimento, tais como Visual Geometry Group 16 (VGG16), Inception V3, ResNet-101 e DenseNet-201 são utilizadas para extrair características de imagens cerebrais de MRI (WAGEH *et al.*, 2024). Outro estudo utiliza as seguintes arquiteturas: VGG-16, InceptionV3, VGG19, ResNet50, InceptionResNetV2 e Xception (HOSSAIN *et al.*, 2024). E outro trabalho que utiliza VGG-16, VGG-19, Inception-v3, ResNet-50, DenseNet e MobileNet, concluiu que VGG-16 obteve melhor resultado (SHAMSHAD *et al.*, 2024). Além dessas pesquisas, também foi encontrado um artigo que menciona o uso de técnicas de transferência do conhecimento associadas a redes de aumento de dados (*Generative Adversarial Network (GAN)*) (NAG *et al.*, 2024).

Apesar destes estudos, não foram encontradas na literatura científica comparações aprofundadas de alguns classificadores para MRI, nas mesmas condições e parâmetros e com um número reduzido de imagens do mesmo banco de dados que este trabalho. Diante disto, este

estudo envolve investigar o desenvolvimento de um sistema detector de neoplasias cerebrais, o qual requer técnicas de aprendizagem de máquina que foram utilizadas para comparação entre diferentes classificadores, CNN, por exemplo. Isto porque CNN tem sido utilizada frequentemente na literatura, devido seus resultados de desempenho consideráveis (como, por exemplo, acurácia acima de 90%).

Adicionalmente, algumas estratégias serão implementadas, tais como, redes customizadas e pré-treinadas, testando a influência de aumento de dados de treinamento; extração de características por CNNs seguida de classificação; transferência de conhecimento; e Redes Adversárias Generativas para geração de imagens utilizadas no treinamento das redes. Essas estratégias foram utilizadas com o intuito de melhorar os resultados obtidos, considerando as arquiteturas de CNN mais simples possíveis, que possam ser treinadas com bases de dados com número reduzido de imagens, em relação a literatura, que tenham resultados de desempenho promissores e, conseqüentemente, estejam presentes em pesquisas no estado da arte.

1.2 DEFINIÇÕES DO PROBLEMA CIENTÍFICO E PROPOSTA

O processo de detecção de neoplasias cerebrais é, segundo alguns estudos, relativamente desafiador, devido a ampla variedade de neoplasias em diferentes pacientes e sua semelhança com os tecidos saudáveis (ARIF *et al.*, 2022). Além disso, é essencial analisar diversas características, tais como variações na localização, forma e tamanho do tumor (AMIN *et al.*, 2022).

Portanto, é relevante explorar métodos alternativos para a detecção de neoplasia cerebral, devido a necessidade de detecção precoce. Sendo assim, a ideia é que possa ocorrer, inclusive em um momento de triagem. Para detectar automaticamente neoplasias cerebrais, técnicas de aprendizado de máquina aplicadas às imagens médicas podem ser utilizadas. Uma dessas técnicas é a Rede Neural Convolutiva (CNN), um tipo de aprendizado profundo. O aprendizado profundo tornou-se predominante no campo do aprendizado de máquina, inclusive em aplicações relacionadas a imagens cerebrais (SCHULZ *et al.*, 2020; KHAN *et al.*, 2022; NAYAK *et al.*, 2022; TANDEL *et al.*, 2019).

Após revisão sistemática da literatura científica, verificou-se que existem diversas soluções

baseadas em treinamento a partir de bases com número relevante de imagens, em relação a este trabalho, e que possuem, inclusive, resultados de acurácia, especificidade, precisão e sensibilidade acima de 90%. Mas há relativamente poucos estudos comparando de maneira sistemática o desempenho em cenários com bases com quantidades de dados menores, analisando apenas um corte, levando em conta modelos de diferentes complexidades e diferentes técnicas de aumento de dados.

Diante disto, este estudo consiste em investigar um sistema classificador de MRI, em que foram escolhidas as imagens de neoplasias cerebrais, pois existem estudos desse tipo de análise que possuem desempenho relevante (como, por exemplo, acurácia acima de 90%) para este tipo de análise. Logo, algumas estratégias serão implementadas com o intuito de melhorar os resultados obtidos na literatura, considerando as arquiteturas de CNN mais simples possíveis, que possam ser treinadas com bases de dados com menor número de imagens. Incluindo análises de diferentes técnicas de aumento de dados, com o intuito de elevar os resultados das medidas de desempenho, considerando quantidade de dados reduzidas obtidas do banco de dados utilizado (CHENG, 2017).

Esse trabalho propõe investigar com que desempenho essas classificações automatizadas podem ser treinadas, inclusive com apenas imagens relacionadas a um único corte (ver Figura 2.3) para melhorar a eficiência dos classificadores e reduzir o custo computacional. Além disso, a contribuição deste estudo é indicar qual arquitetura apresenta resultado melhor, tais como classificação desenvolvida a partir de uma arquitetura customizada e com rede pré-treinada (Estratégia 1), com extração de características utilizando CNN (Estratégia 2) e com transferência de conhecimento (Estratégia 3). Além disso, utilizar Redes Adversárias Generativas para geração de imagens para o treinamento de alguns dos modelos anteriores que possuem melhores resultados.

Neste contexto, para determinar a melhor estratégia de classificação, análises dos resultados foram realizadas utilizando medidas, tais como acurácia, precisão, *recall* e medida-F. A acurácia consiste na proporção de previsões corretas sobre o total de casos; a precisão consiste em entre os casos previstos como classe x , quantos realmente são da classe x ; *recall* consiste em entre os casos realmente da classe x , quantos foram corretamente identificados; e a medida-F é a média harmônica entre precisão e *recall*.

Essas medidas foram selecionadas para este trabalho, pois são comumente utilizadas na literatura, sobretudo na literatura médica. Visto que os falsos negativos são os erros mais graves na área médica, logo a medida de *recall* avalia este tipo de situação, pois ajuda a evitar que casos graves ocorram neste tipo de análise. Essas medidas isoladas podem ocasionar uma interpretação equivocada dos resultados, logo, essas em conjunto refletem de forma adequada o impacto prático de sua aplicação no contexto médico.

Avaliando essas métricas, o intuito deste trabalho é investigar e verificar as melhores estratégias para classificar doenças cerebrais em MRI com maiores resultados de desempenho, podendo, inclusive, ocorrer em um momento de diagnóstico, triagem ou como um achado incidental.

1.3 OBJETIVOS

1.3.1 Objetivo Geral

Investigar o desenvolvimento de um sistema de auxílio ao diagnóstico médico, utilizando modelos de classificação, com valores de desempenho superiores aos alcançados pela literatura, a partir de diferentes classificadores de MRI do cérebro de diferentes cortes, relacionados a detecção de neoplasias cerebrais, utilizando e comparando diferentes técnicas de aprendizado de máquina, selecionando arquiteturas que possam ser treinadas com bases menores, quando comparadas ao que é reportado na literatura.

1.3.2 Objetivos específicos

- 1 Investigar o desenvolvimento de um sistema automatizado de auxílio a diagnóstico médico de MRI, por meio de um estudo de caso com análise de imagens de cérebro de neoplasias cerebrais (meningioma, glioma e adenomas de hipófise);
- 2 Explorar abordagens de classificação automática de neoplasias cerebrais de MRI utilizando aprendizado profundo, com estratégias, tais como, técnicas de aumento de dados tradicionais, com redes pré-treinadas, modelos de características extraídas por CNNs e

transferência de conhecimento, inclusive, utilizando base menor possível, além de utilizar Redes Adversárias Generativas para geração de imagens de treinamento das redes;

- 3 Comparar performance de métricas de diferentes sistemas classificadores que detectam neoplasias cerebrais utilizando MRI, usando métricas de avaliação do desempenho, tais como acurácia, precisão, *recall* e medida-F, selecionando arquiteturas com melhores resultados e que possam ser treinadas com bases menores.

1.4 JUSTIFICATIVA E CONTRIBUIÇÕES

Atualmente, o estado da arte apresenta o uso de AI para detecção de neoplasias cerebrais de MRI como uma ferramenta de auxílio a diagnóstico médico, podendo ser aplicado em uma triagem ou também em achados incidentais. Existem alguns desafios para classificar automaticamente MRI, como por exemplo, o custo computacional, ocasionado, sobretudo, pelas CNN (AKINYELU *et al.*, 2022) e também a necessidade de grande volume de dados para treinar adequadamente modelos de aprendizagem. Apesar disso, o aprendizado profundo, em geral, produz resultados de desempenho superiores em comparação com outras técnicas.

Diante disso, é importante verificar técnicas de aprendizagem de máquina que tenham desempenho comparáveis ao estado da arte utilizando essas situações desafiadoras aqui mencionadas. Diversas soluções na literatura científica utilizam bases com maiores números de imagens, em relação a este trabalho, e possuem, inclusive, resultados de métricas de desempenho acima de 90%. Entretanto, há relativamente poucos estudos comparando de maneira sistemática o desempenho, avaliando modelos de diferentes complexidades e diferentes técnicas de aumento de dados, sobretudo em cenários com menores números de imagens em relação aos estudos existentes na literatura.

Logo, este trabalho propõe a investigação da classificação de diferentes tipos de neoplasias cerebrais, tais como, meningioma, glioma e adenomas de hipófise, sobretudo com imagens selecionadas de apenas um corte, para redução do custo computacional e simplificação das estratégias utilizadas, com quantidades de imagens suficientes para obter um desempenho expressivo, segundo a literatura. Além disso, este trabalho consiste em aplicar diversas abordagens de aumento de dados com intuito de desenvolver sistemas com métricas de desempenho superiores.

Isto envolve a avaliação sistemática de várias ferramentas de aprendizado de máquina para obter os resultados de classificação satisfatórios, de acordo com o que a literatura apresenta, sobretudo as CNNs, que são utilizadas frequentemente. Visto que, realizam a extração e classificação de dados de maneira automática com resultados relevantes, conforme o estado da arte.

Em resumo, esta pesquisa está relacionado a investigação de uma ferramenta de auxílio a diagnóstico médico em uma maneira de detecção não invasiva de neoplasias cerebrais. Além de contribuir com o diagnóstico precoce, facilitando a detecção, que pode ser, inclusive, realizada durante uma triagem ou um achado incidental, e, conseqüentemente, melhorando a qualidade de vida dos pacientes, visto que com o diagnóstico precoce, o tratamento será iniciado precocemente também.

Para isso, a ideia é selecionar arquiteturas mais simples possíveis e que possam ser treinadas com bases menores, contribuindo assim com o avanço científico nesta área de estudo. Diante disso, após avaliação sistemática, as estratégias utilizadas neste trabalho podem, inclusive, contribuir para estudos científicos relacionados a outras aplicações de AI em MRI de cérebro, além de neoplasias cerebrais, como, por exemplo, estudos relacionados ao Alzheimer e doenças de Parkinson.

CAPÍTULO 2

FUNDAMENTAÇÃO TEÓRICA

2.1 FUNDAMENTAÇÃO MÉDICO-CIENTÍFICA

De acordo com o Instituto Nacional de Câncer (INCA), a neoplasia no Sistema Nervoso Central (SNC), que engloba o cérebro e a medula espinhal, constitui de 1,4% a 1,8% dos tumores malignos no mundo. Além disso, 88% dos tumores no SNC estão concentrados no cérebro (INCA, 2022). Portanto, é importante estudar como detectar essa doença precocemente para prevenir complicações futuras.

2.1.1 Evolução histórica das neoplasias cerebrais

Segue uma breve história dessa doença em diferentes séculos: da Antiguidade ao século XXI (Antiguidade, século XVII, século XIX, século XX e século XXI).

Antiguidade

Na Antiguidade, os médicos já tinham conhecimento de certas doenças relacionadas ao cérebro, embora neoplasias cerebrais ainda não fossem reconhecidos (PP; KP, 2015). Como não havia tratamentos disponíveis para neoplasias cerebrais na época, essa doença se manifestava com sintomas como dores de cabeça, convulsões e coma, resultando, no pior caso, na morte do indivíduo (CASTILLO, 2014).

Apesar da falta de tecnologia na época, na Antiguidade várias pessoas iniciaram o estudo que desde então tem levado a inúmeros avanços no campo das neoplasias cerebrais no setor de saúde. Indivíduos notáveis incluem Celsus, Herophilus e Galen, como também Rhazes e Avicenna, Alcmaeon, Praxagoras, e Herophilus (HOLMES, 2021; PP; KP, 2015). Hipócrates (460-370 a.C.), frequentemente considerado o pai da medicina, contribuiu significativamente

para compreensão das lesões neurológicas atuais. Além disso, Rhazes e Avicenna (980–1037) conduziram estudos sobre doenças cerebrais (HOLMES, 2021).

Finalmente, na Grécia Antiga, três figuras importantes na história da medicina que estudaram o sistema nervoso foram Alcmaeon, Praxagoras e Herophilus. Alcmaeon introduziu teorias significativas sobre o cérebro e o sistema nervoso. Os estudos de Praxagoras sugeriram a existência de neurônios. Herophilus, em particular, diferenciou entre nervos sensoriais e motores e forneceu evidências do sistema nervoso (PP; KP, 2015). Assim, devido à tecnologia limitada disponível durante a Antiguidade, houve poucos estudos sobre neoplasias cerebrais, e como resultado, essa doença frequentemente resultava em fatalidades.

Século XVII

No século XVII, o conhecimento médico sobre doenças, incluindo a compreensão da anatomia e fisiologia humana, como neoplasias cerebrais, permanecia limitado devido à falta de tecnologia. Conseqüentemente, o conhecimento médico estava em estágios iniciais durante este século e também era influenciado por crenças culturais e filosóficas da época.

O diagnóstico de neoplasias cerebrais era extremamente desafiador nesse período, principalmente devido à ausência de tecnologias de imagem, como RM ou TC, que são cruciais para a visualização não invasiva do cérebro atualmente. Como resultado, não foram identificados estudos específicos sobre o tratamento ou diagnóstico de neoplasias cerebrais no século XVII.

Além disso, foi somente no século XVII (1621-1675) que Thomas Willis, que também estudou o sistema nervoso, começou a utilizar o termo ‘neurologia’. Ele descobriu que a função neurológica dependia principalmente do cérebro, em vez de suas cavidades (JR; KAYE, 2002).

Somente em séculos posteriores, por meio do estudo da anatomia, da dissecação de cérebros humanos e dos avanços em tecnologias de diagnóstico, discutidos mais detalhadamente nas seções seguintes, que uma compreensão mais profunda do sistema nervoso central e das doenças que o afetam, como neoplasias cerebrais e seus tratamentos, começou a progredir significativamente.

Século XIX

Diferentemente dos séculos anteriores, no século XIX ocorreu um aumento nos estudos relacionados a neoplasias cerebrais. Isso se deve, como está explicado mais detalhadamente a seguir, a avanços em áreas como anestesia, tecnologia de microscópios, estudos sobre anatomia cerebral e cirurgia de neoplasias cerebrais, entre outros.

No século XIX, ocorreram desenvolvimentos significativos, incluindo a descoberta da anestesia, assepsia e a localização de lesões cerebrais. O avanço da anestesia foi especialmente relevante nas práticas cirúrgicas. Como resultado dessas inovações, tornou-se possível realizar as cirurgias de remoção de neoplasias cerebrais que atualmente são comuns (JR; KAYE, 2002).

Além disso, a partir do século XIX, houve progresso tecnológico significativo no desenvolvimento de microscópios. O físico que colaborou com Carl Zeiss (1816–1888), Ernst Abbé (1840–1905), conduziu pesquisas sobre novas fórmulas matemáticas e teorias que levaram a melhorias na qualidade óptica das lentes (HOLMES, 2021).

Em 1835, nasceu na Inglaterra uma pessoa chamada John Hughlings Jackson. Ele tornou-se um dos maiores pesquisadores que contribuíram para nossa compreensão contemporânea da localização anatômica do cérebro. Em 1870, os cientistas alemães Gustav Fritsch e Eduard Hitzig conduziram estudos sobre a excitabilidade elétrica do córtex cerebral em cães, utilizando corrente galvânica (KERR *et al.*, 2005).

Um artigo científico relata que a primeira remoção de neoplasias cerebrais foi realizada em 1879 em uma jovem por William Macewen (PREUL, 2005). Além disso, em 1881, o Dr. William Macewen de Glasgow da Escócia, apresentou um estudo sobre a remoção, que foi bem sucedida, de um meningioma frontal esquerdo em uma menina de 14 anos que sobreviveu ao procedimento ocorrido dois anos antes. A paciente tinha convulsões que cessaram após o procedimento. Isso não foi uma tarefa fácil devido à tecnologia limitada disponível naquela época em comparação com hoje (KERR *et al.*, 2005; MACEWEN, 1965)

Em 1884, Rickman Godlee conduziu uma operação cirúrgica que marcou progresso significativo em estudos e técnicas relacionadas ao campo neurológico. Isso incluiu avanços em técnicas de imagem para visualização de neoplasias cerebrais e uma compreensão mais profunda da biologia desses tumores, entre outros benefícios. Foi a primeira vez que um tumor foi identificado

exclusivamente por métodos neurológicos. Além disso, em 1887, William W. Keen realizou a primeira remoção de meningioma nos EUA (JR; KAYE, 2002). Em 1895, a capacidade de localizar lesões foi expandida quando Wilhelm Roentgen descobriu os raios-X (KERR *et al.*, 2005).

Portanto, em resumo, torna-se evidente que um desenvolvimento significativo no estudo de neoplasias cerebrais teve início no século XIX. Durante este século, houve avanços na pesquisa de anestesia, tecnologia de microscópios, estudos sobre anatomia cerebral e cirurgia de neoplasias cerebrais, entre outros desenvolvimentos cruciais.

Século XX

No século XX, avanços tecnológicos possibilitaram uma progressão substancial nos estudos de neoplasias cerebrais. Uma das principais razões para isso foi a utilização de imagens médicas. Além disso, no campo das cirurgias de neoplasias cerebrais ocorreu um progresso significativo. Este tópico será discutido com mais detalhes a seguir.

No século XX, avanços tecnológicos, especialmente a introdução da TC e da RM, resultaram em um desenvolvimento significativo nas técnicas de diagnóstico de neoplasias cerebrais. Essas inovações permitiram a visualização não invasiva do cérebro, possibilitando a detecção precoce de doenças cerebrais e a identificação precisa da localização de tumores.

Em 1918, Dandy conduziu um estudo e desenvolveu o pneumoencefalograma (abordagem antiga utilizada para examinar o cérebro por meio de imagens). Isso representou um avanço significativo na pesquisa cerebral, contribuindo para os estudos relacionados à localização radiológica de lesões no sistema nervoso central (KERR *et al.*, 2005)

Além disso, a primeira remoção de neoplasias cerebrais usando eletrocauterização (dispositivo médico que elimina lesões cutâneas e imperfeições por meio de descarga elétrica) foi realizada por Harvey Cushing, considerado o pai da neurocirurgia moderna, em 1926. Ele desempenhou um papel crucial no avanço da cirurgia de neoplasias cerebrais. Entre suas inúmeras contribuições, ele introduziu métodos anestésicos e dispositivos eletrocirúrgicos (KOMORI, 2017).

Assim, o século XX marcou o início de estudos mais abrangentes sobre neoplasias cerebrais,

principalmente devido às inovações tecnológicas. Esses avanços facilitaram o desenvolvimento de técnicas de imagem para detecção e localização precisa de tumores por meio de análises médicas, juntamente com progressos notáveis na cirurgia de neoplasias cerebrais, entre outros fatores.

Século XXI

No século presente, é importante destacar os avanços tecnológicos na imagem médica, que têm simplificado o diagnóstico e a localização de neoplasias cerebrais. Nesse contexto, deve-se enfatizar as contribuições da AI.

A evolução histórica recente no século XXI tem sido caracterizada pela utilização TC e RM. Essas técnicas capacitaram os médicos a visualizar a estrutura do cérebro e determinar a presença, localização e características dos tumores (LOUIS *et al.*, 2007).

Um aspecto importante é a tendência atual em que essas identificações são realizadas por técnicas de aprendizado de máquina. Neste contexto, a AI pode auxiliar na identificação precisa de regiões tumorais, prever o comportamento dos tumores e selecionar os tratamentos mais adequados.

Assim, enquanto neoplasias cerebrais continuam tendo graves consequências, no século XXI tem ocorrido progressos significativos em sua detecção e tratamento. Isso inclui a utilização de aprendizado de máquina para a classificação automática de neoplasias cerebrais em imagens de RM, com ênfase recente no aprendizado profundo.

Além disso, o advento da tecnologia proporcionou várias vantagens. Por exemplo, melhorou as técnicas de diagnóstico, reduzindo riscos cirúrgicos associados à remoção de tumores (PREUL, 2005). Além disso, devido as atuais inovações tecnológicas, pesquisas em robótica, biotecnologia e nanomedicina transformam substancialmente o campo da cirurgia de neoplasias cerebrais (HOLMES, 2021).

Conseqüentemente, sobre os avanços tecnológicos do século XX, a utilização de imagens de TC e RM continua sendo de grande relevância para estudos e procedimentos relacionados a neoplasias cerebrais no século XXI. No entanto, com o surgimento da AI, aprendizado de máquina e técnicas de aprendizado profundo, elas se tornaram ferramentas automáticas para

auxiliar os médicos no diagnóstico de neoplasias cerebrais.

2.1.2 Epidemiologia global de neoplasias no Sistema Nervoso Central

O câncer é um tipo de tumor maligno (NIH, 2021). De acordo com a Agência Internacional de Pesquisa sobre o Câncer, em 2020, foram registrados 19.292.789 casos de câncer no mundo, abrangendo todas as idades e sexos (International Agency for Research on Cancer, 2023).

Além disso, neoplasias cerebrais afetam o sistema nervoso central. Em 2020, a Agência Internacional de Pesquisa sobre o Câncer registrou 207.228 casos de mortes por neoplasias cerebrais (sistema nervoso central), abrangendo todos os gêneros e idades de 0 a 74 anos, excluindo o câncer de células escamosas (células finas e planas que compõem a camada mais externa da pele (epiderme)) não melanoma (International Agency for Research on Cancer, 2023). Melanoma é um tipo diferente que se origina nos melanócitos (células que produzem melanina) e é mais agressivo.

O gráfico na Figura 2.1 ilustra as quantidades de mortes relacionadas a tumores do sistema nervoso central (CNS) no Brasil. Em 2020, foram registrados 9355 casos, com 4787 em homens e 4567 em mulheres. Em 2022, o número de mortes aumentou para 11490, sendo 6110 em homens e 5380 em mulheres (INCA, 2022). O gráfico destaca um maior número de mortes relacionadas a tumores do CNS em homens, com um aumento significativo na diferença de gênero em 2022.

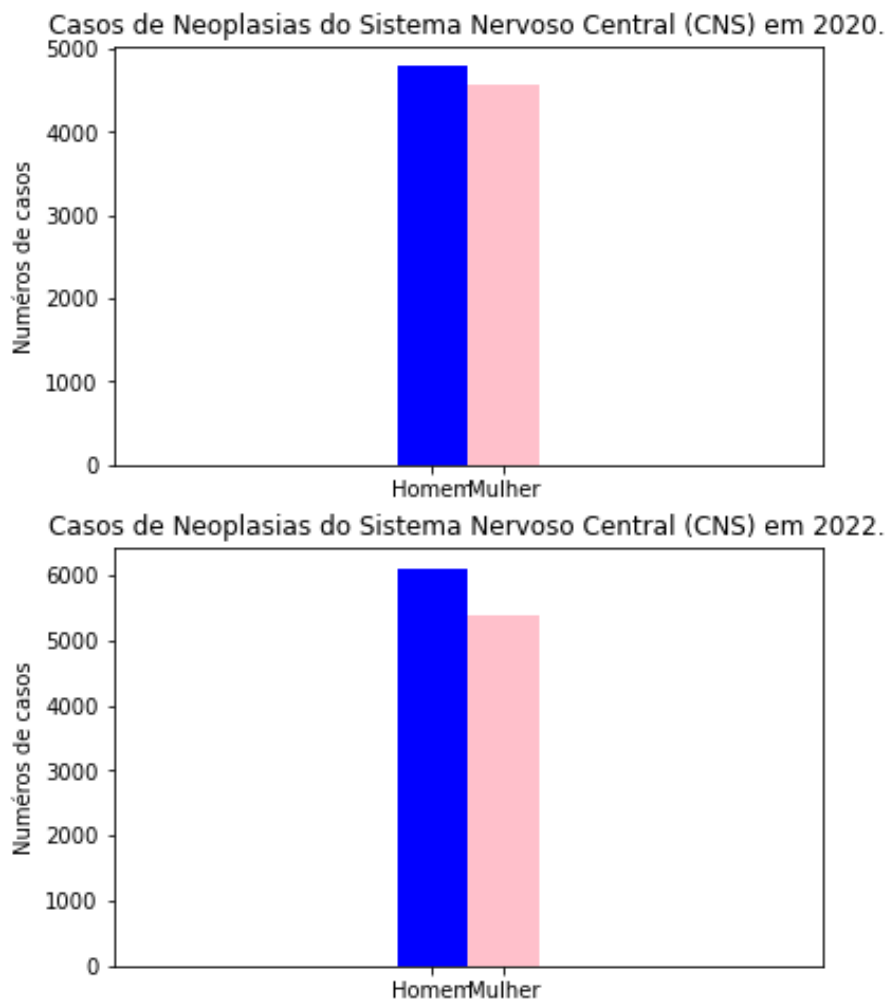


Figura 2.1: Quantidades de mortes relacionadas a tumores do sistema nervoso central (CNS) no Brasil em 2020 e 2022.

Fonte: Dados de (INCA, 2022).

2.1.3 Tipos de Neoplasias Cerebrais

Segundo o Instituto Nacional do Câncer (INCA), algumas causas de neoplasias no Sistema Nervoso Central (SNC) incluem exposição à radiação, arsênio, chumbo, mercúrio, bem como trabalhos em várias indústrias, como petroquímica, borracha, plástico, gráfica, papel, têxtil e pesticidas. Outros fatores de risco incluem empregos relacionados a refinarias, usinas nucleares, produção e reparo de veículos automotores, serviços elétricos e telefônicos, agricultura, entre outros (INCA, 2022). Notavelmente, a radiação iônica é o principal fator de risco para tipos específicos de neoplasias do sistema nervoso, especialmente os denominados neoplasias gliais e meníngeas (DEANGELIS, 2001).

Neoplasias cerebrais causam dois tipos diferentes de sintomas neurológicos: focais e generalizados. Os primeiros ocorrem devido à localização intracraniana do tumor. Os segundos ocorrem devido ao aumento da pressão intracraniana. Isso pode causar dor de cabeça e, em casos mais graves, náusea, vômito, entre outros sintomas (DEANGELIS, 2001).

Como mencionado anteriormente, um tipo específico de neoplasia no sistema nervoso é a neoplasia glial. Esses podem ser categorizados como *astrocytic* ou *oligodendroglial*, e ambos os tipos podem ser de alto ou baixo grau (DEANGELIS, 2001).

Neoplasias *astrocytic* geralmente ocorrem em adultos jovens, principalmente entre as idades de 30 e 40 anos. O primeiro sintoma dessa condição costuma ser convulsões, e nos casos em que a cirurgia não é necessária, a radioterapia é uma opção comum de tratamento (DEANGELIS, 2001).

A neoplasia *oligodendroglial*, por outro lado, é principalmente do tipo de baixo grau. Esse tipo está associado à vascularização que pode levar a hemorragias. O diagnóstico e o tratamento de neoplasias *oligodendroglial* são semelhantes aos de astrocitomas de baixo grau. É importante destacar que pacientes com neoplasias *oligodendroglial* têm uma taxa de sobrevida média consideravelmente mais longa, aproximadamente 10 anos, em comparação com a taxa de sobrevida média de 5 anos para astrocitomas de baixo grau (DEANGELIS, 2001).

Este trabalho trata de três diferentes tipos de neoplasias cerebrais, tais como, meningioma, glioma e adenomas de hipófise. A Figura 2.2 exhibe exemplos de RM desses três tipos diferentes de neoplasias cerebrais, respectivamente, com a região de neoplasia identificada.




Figura 2.2: Exemplos de imagens de neoplasias cerebrais: Esquerda - Meningioma, Meio - Glioma, Direita - adenomas de hipófise

Fonte: Imagens obtidas do banco de dados: (CHENG, 2017).

O meningioma consiste em tipo de neoplasias localizadas nas meninges e surge nas células denominadas ‘meningoteliais’ (OSBORN, 2014). Ele é a neoplasia benigna mais comum do cérebro. E corresponde a 15% de todas neoplasias intracranianas em adultos. Além disso, sua incidência ocorre sobretudo em adultos, sendo raros os casos em indivíduos menores de 30 anos (RUNGE *et al.*, 2015). Além disso, é importante enfatizar que, embora os meningiomas sejam classificados como neoplasias cerebrais, eles não estão localizados dentro do cérebro em si. Em vez disso, eles se originam na membrana externa do cérebro (DEANGELIS, 2001).

Além disso, o glioma, que se desenvolve a partir de células gliais, é considerado um dos tipos mais variados de neoplasias cerebrais (OSBORN, 2014). Essa heterogeneidade permite que esse tipo de neoplasia possa apresentar diferentes formas de crescimento, sintomas e, conseqüentemente, distintas respostas ao tratamento, o que torna sua identificação e acompanhamento clínico um desafio.

E os adenomas localizados na hipófise são classificados pelo tamanho. São chamados de ‘microadenomas’ quando são menores ou iguais a 10 mm e ‘macroadenomas’ quando são maiores ou iguais a 11 mm. Além disso, os adenomas de hipófise estão localizados nas regiões do cérebro denominada selar e supracelular. Sendo que a região selar é uma das áreas mais complexas do cérebro (OSBORN, 2014).

2.1.4 Modalidades de aquisição de imagens médicas

Os métodos de detecção de neoplasias cerebrais podem ser invasivos ou não invasivos. A detecção invasiva envolve a biópsia, enquanto os métodos não invasivos incluem a TC e a RM (RM) (TANDEL *et al.*, 2019).

A TC consiste na emissão de raios x por meio de radiação ionizante. Ela detecta partes ósseas, calcificações e hemorragias. Alguns tomógrafos com múltiplas fileiras de detectores possuem tempo de exame reduzido (LEITE *et al.*, 2008).

Já a RM é composta por magneto principal, bobinas transmissoras e receptoras de radio-frequência (rF) os quais geram emissão de energia e promovem a recepção de sinal. O sinal de RM é codificado, digitalizado por conversor analógico - digital e salvo no computador. Sendo realizado processamento matemático do sinal por meio de transformada de *Fourier* para que as imagens sejam reconstruídas (LEITE *et al.*, 2008).

O principal teste diagnóstico para neoplasias cerebrais é a RM (DEANGELIS, 2001), sendo, portanto, uma das técnicas de imagem não invasiva usada para capturar imagens da estrutura do cérebro, medula espinhal, assim como de outros órgãos e estruturas como ossos, músculos, tecidos moles e tumores.

Para obter as MRIs, o paciente precisa passar de trinta minutos a uma hora dentro da máquina. As imagens produzidas pela MRI permitem a identificação precoce de certos tipos de anormalidades em regiões específicas do corpo e auxiliam no diagnóstico médico.

A RM produz imagens em vários planos, incluindo sagital, axial e coronal. Cada um dos cortes é descrito abaixo:

Plano sagital: Divide o corpo em duas partes, direita e esquerda, e mostra as estruturas longitudinais;

Plano axial: Este plano é perpendicular ao eixo longitudinal do corpo, mostrando estruturas cortadas transversalmente;

Plano coronal: Divide o corpo em partes anterior e posterior, mostrando as estruturas cortadas frontalmente.

Exemplos desses cortes são mostrados na Figura 2.3, com o plano sagital à esquerda, o plano axial no meio e o plano coronal na figura à direita.




Figura 2.3: Exemplos dos três cortes de MRI de diferentes pacientes (à esquerda: sagital, meio: axial, direita: coronal).

Fonte: Imagens obtidas do banco de dados: (CHENG, 2017).

Além das RM comuns, existe um tipo de ressonância, denominada ‘Ressonância Magnética Funcional (RMf)’, em que o paciente realiza determinada tarefa enquanto são obtidas imagens do cérebro. Algumas desvantagens dessa técnica são o ruído acústico, artefatos de movimento, ambiente claustrofóbico... Apesar disso, ela possui algumas vantagens, como por exemplo, ausência de radiação ionizante, não depende do contraste, boa resolução espacial e temporal (LEITE *et al.*, 2008).

Além desses dois principais tipos, TC e RM, existe a radiografia. Entretanto, as radiografias cranianas não são muito utilizadas atualmente, visto que na maioria dos casos, é necessária a investigação do cérebro, não do crânio (OSBORN, 2014).

Dentre os tipos de aplicações de MRI, existe um protocolo denominado DICOM. O *DICOM* (*Digital Imaging and Communications in Medicine*) é um padrão internacional criado em 1983 para padronizar o armazenamento e a comunicação de imagens médicas, como raios-X, ressonâncias e tomografias... Ele define um formato eletrônico unificado que inclui tanto a imagem quanto metadados (dados do paciente, exame e equipamento) (NEMA, 2023; UCSF - University of California, San Francisco, 2024).

As principais funções e benefícios do protocolo DICOM são padronização de formatos de imagens médicas; facilidade na troca de dados entre diferentes sistemas e fabricantes; permissão de acesso e análise de imagens em softwares compatíveis; melhora do fluxo de trabalho em hospitais e clínicas; além disso, conseqüentemente, favorece a interação da medicina na pesquisa

(NEMA, 2023; DICOM Standard, 2023; PIZER; ACKERMAN, 1996).

Em resumo, existem duas principais técnicas para detecção de imagens do corpo humano, TC e RM. Neste trabalho, o foco é o estudo de RM, visto que, diversos estudos analisam esse tipo de imagens para o desenvolvimento de sistemas automatizados de diagnóstico utilizando AI. Promovendo assim, uma investigação de ferramentas para auxílio ao diagnóstico médico.

2.2 INTELIGÊNCIA ARTIFICIAL

A aprendizagem de máquina consiste na detecção automatizada de padrões (SHALEV-SHWARTZ; BEN-DAVID, 2014). É uma subárea da AI (ALPAYDIN, 2014) e uma disciplina científica que, dentre diversas aplicações, abrange a classificação de imagens.

De acordo com a Enciclopédia Britânica, a aprendizagem de máquina é um ramo da AI que envolve o aprendizado de forma automática utilizando computador (HOSCH, 2022). O processo de aprendizagem de máquina compreende algoritmos para extração de características e classificação de imagens. A extração de características e a classificação podem ser realizadas separadamente usando várias técnicas, mas também podem ser automatizadas por meio de algoritmos de aprendizagem profunda.

Além disso, existem dois tipos de problemas de aprendizagem: classificação e regressão. A classificação lida com valores pequenos e discretos (WERNICK *et al.*, 2010). Envolve um vetor de características de entrada, que pode consistir em valores discretos ou contínuos, e a saída é representada por valores discretos, que são as classes (DOMINGOS, 2012). Um exemplo de classificação é o estudo deste trabalho que consiste na identificação de neoplasias cerebrais em imagens de RM. Ao contrário da classificação, a regressão lida com variáveis de saída contínuas. Por exemplo, pode ser usada na avaliação diagnóstica da gravidade de uma doença (WERNICK *et al.*, 2010).

Outro conceito importante é a mineração de dados, que engloba técnicas de aprendizagem de máquina para analisar grandes bancos de dados. Alguns exemplos de aplicações de mineração de dados incluem finanças, detecção de fraudes, mercado de ações, manufatura, medicina, telecomunicações e ciência... (ALPAYDIN, 2014).

O processo de desenvolvimento de aprendizado de máquina envolve o reconhecimento de

padrões. Isso é semelhante ao que acontece em nosso cérebro quando é identificado inconscientemente características como cor dos olhos, formato do rosto e tamanho para reconhecer uma pessoa (ALPAYDIN, 2014). Diante disso, o primeiro passo nesse processo é extrair características, que são relevantes em um sistema classificador (DOMINGOS, 2012).

2.2.1 Fatores históricos da evolução da Inteligência Artificial

Em 1943, McCulloch e Pitts conduziram o primeiro estudo, que inicializou o que se conhece como AI (MCCULLOCH; PITTS, 1943). Em 1950, dois estudantes universitários, Marvin Minsky e Dean Edmonds, em Harvard, desenvolveram o primeiro computador de rede neural (RUSSELL; NORVIG, 2010).

Além disso, a AI foi estabelecida em 1956 (RUSSELL; NORVIG, 2010). Ao mesmo tempo, John McCarthy introduziu esse termo em uma conferência e o definiu como "a ciência e a engenharia do desenvolvimento de sistemas inteligentes" (LUGER, 2004).

É importante mencionar que o desenvolvimento de AI deu origem a vários subconjuntos, como aprendizado de máquina, que por sua vez levou ao surgimento do aprendizado profundo (*Deep Learning*). Portanto, os tópicos seguintes, Aprendizado de Máquina e Aprendizado Profundo, são subáreas da AI.

Classificação

Após a extração de características, essas características são utilizadas para treinar sistemas classificadores. Esse processo encontra aplicações em diversos campos, como inteligência empresarial, detecção de spam em e-mails, detecção de fraudes... Além disso, uma aplicação significativa está no domínio de imagens médicas, que é o foco deste estudo. Um exemplo nesse contexto é o desenvolvimento de um algoritmo que determina se a imagem de um indivíduo, conforme vista em imagens médicas, corresponde a um estado saudável ou doente (WERNICK *et al.*, 2010).

De fato, existem três tipos principais de classificação em aprendizado de máquina: supervisionada, não supervisionada e aprendizado por reforço. No aprendizado supervisionado, a

abordagem mais comum na literatura, rótulos (que são as classes) são fornecidos ao sistema durante o processo de treinamento, enquanto no aprendizado não supervisionado essa informação dos rótulos não é fornecida, em vez disso, o sistema aprende por meio de cálculos matemáticos durante a fase de classificação. No aprendizado por reforço, o sistema aprende as suas melhores ações.

Quando se trata de classificação de imagens em aprendizado de máquina usando aprendizado supervisionado, vários métodos e algoritmos podem ser empregados. Alguns dos mais utilizados incluem Máquinas de Vetores de Suporte, K-Vizinhos Mais Próximos, métodos *ensemble*, Regressão Logística, Naive Bayes, Árvores de Decisão, entre muitos outros.

Técnicas de aprendizado profundo têm ganhado significativa popularidade para tarefas de classificação de imagens devido a seus resultados notáveis. Essas técnicas permitem que tanto a extração de características quanto a classificação sejam realizadas automaticamente. A escolha de uma técnica específica de classificação frequentemente depende de seus resultados de desempenho, bem como do custo computacional associado a ela.

Durante o processo de classificação, existem duas etapas principais: treinamento e teste. Na etapa de treinamento, o sistema utiliza as características como entrada e, por meio de cálculos matemáticos e estatísticos, constrói um modelo de otimização que distingue entre diferentes classes dentro do conjunto de dados. Após o treinamento, métricas estáticas são empregadas para testar os resultados gerados pelo classificador, utilizando um conjunto de dados que não deve ser utilizado no processo de treinamento (ALPAYDIN, 2014).

A classificação envolve mapear os dados de entrada de um sistema para classes de saída, geralmente durante a fase de teste no aprendizado. O objetivo é encontrar uma função que separe efetivamente os dados em classes distintas com base em suas características (HASTIE *et al.*, 2009). Métricas matemáticas são obtidas para auxiliar essa análise.

Aprendizado de Máquina

O termo "aprendizado de máquina" foi utilizado pela primeira vez por Arthur Samuel em 1959 (GEROVITCH, 2015; LINDSAY, 1964). Ele desenvolveu um programa para jogar damas que aprimorava suas habilidades por meio da experiência (SAMUEL, 1959).

No século XXI, com os avanços na tecnologia, a utilização do aprendizado de máquina obteve melhorias substanciais. Esses avanços revolucionaram o aprendizado de máquina, especialmente em áreas como reconhecimento de fala, visão computacional, medicina e outros. Notavelmente, houve um aprimoramento significativo nas técnicas de aprendizado profundo atualmente.

Aprendizado Profundo

O aprendizado profundo - do inglês *Deep Learning (DL)*, é uma subárea do Aprendizado de Máquina. Ao longo dos anos, a popularidade de DL tem sido alterada em momentos que se tornou mais e menos utilizada. O termo “aprendizado profundo” foi inicialmente utilizado dentro da comunidade de aprendizado de máquina por Rina Dechter em 1986 (DECHTER, 1986).

Enquanto no campo das redes neurais artificiais, foi primeiro utilizado por Igor Aizenberg e colaboradores em 2000 (AIZENBERG *et al.*, 2000). Portanto, o grande uso de DL na indústria começou no início da década de 2000.

DL tem sido empregada devido ao aumento na quantidade de dados e melhorias na infraestrutura de computação de hardware e software. Como resultado, ao longo dos anos o aprendizado tem sido aplicado a tarefas cada vez mais complexas, proporcionando melhores resultados (GOODFELLOW *et al.*, 2016).

Redes convolucionais profundas têm encontrado aplicação no processamento de imagem, vídeo, fala e áudio. Por outro lado, redes têm sido empregadas em tarefas, tais como texto e fala (LECUN *et al.*, 2015).

Além disso, os classificadores de aprendizado profundo são capazes de automatizar os processos de extração de características e classificação. Exemplos de abordagens de aprendizado profundo incluem CNNs, Redes Neurais Recorrentes (RNN), Redes Generativas Adversariais - do inglês *Generative Adversarial Networks (GAN)*, Aprendizado por Reforço (RL), Redes Neurais Transformadoras (*transform*), Rede Neural Profunda (DNN), Rede Neural Profunda Confiável (DBN), Autoencoder Profundo, Máquina de Boltzmann Profunda (DBM), Máquina de Aprendizado Profundo Extremo (DC-ELM), entre outras (AGGARWAL, 2018; NIA *et al.*, 2023).

Em vários artigos científicos, a decisão de utilizar o aprendizado profundo foi tomada devido à sua capacidade de realizar a extração de características automaticamente, bem como a sua capacidade de aprimorar automaticamente a precisão do treinamento, apesar de seu maior custo computacional em comparação com outras estratégias (SOMASUNDARAM; GOBINATH, 2019).

2.2.2 Exemplos de Classificadores

Máquinas de Vetores de Suporte

Máquinas de Vetores de Suporte (SVM) consistem em um modelo de aprendizado supervisionado, que necessita dos rótulos na entrada do sistema classificador, usado principalmente para classificação e regressão.

O objetivo do SVM é encontrar um hiperplano ótimo que separe as classes com a maior distância possível. Esta técnica encontra vetores de suporte, que são os pontos mais próximos do hiperplano, que representa a fronteira de decisão em um espaço multidimensional.

Esta abordagem funciona bem em espaços de alta dimensão e é eficaz mesmo quando o número de amostras é pequeno. Nos casos que não são linearmente separáveis a função dos dados é mapeada para um espaço de dimensão maior, linearmente separável e de dimensão infinita, na maioria das vezes, utilizando, para isso, uma função ϕ associada ao kernel (núcleo) do sistema. A função de kernel mais utilizada é a função de base radial (do inglês, *Radial Basis Function* (RBF)).

Rede Neural Artificial

Um neurônio biológico é composto por dendritos (recebem sinais de outros neurônios), corpo celular (processa os sinais), axônio (transmite o sinal para outros neurônios).

A rede neural artificial (RNA) possui funcionamento, conforme neurônio biológico, em que cada neurônio artificial recebe entradas (valores numéricos), aplica pesos, soma e passa por uma função de ativação, onde o sinal é transmitido para os próximos neurônios da rede. Logo, as redes neurais artificiais aprendem ajustando as conexões (pesos) entre os neurônios para

executar tarefas como classificação, regressão ou detecção de padrões.

Uma rede neural simplificada, chamada de *perceptron*, consiste em uma única camada (entrada), com múltiplos neurônios com seus próprios pesos; não há camadas ocultas. O algoritmo do perceptron aprende os pesos dos sinais de entrada para traçar um limite de decisão linear.

Camadas Multidimensionais

Camadas Multidimensionais (MLPs) consistem em uma das arquiteturas mais básicas de redes neurais. É composta por camada de entrada (recebe os dados, cada neurônio de entrada representa uma característica), uma ou mais camadas ocultas (fazem o processamento).

Para cada neurônio em uma camada oculta ou na camada de saída, a soma ponderada de suas entradas é calculada. Isso envolve multiplicar cada entrada pelo seu peso correspondente, somar esses produtos e adicionar o viés. Além disso, é composta por camada de saída (gera o resultado); cada neurônio de uma camada está conectado com todos os neurônios da próxima (rede totalmente conectada). MLP utiliza, também, funções de ativação não lineares, como ReLU, sigmoid, tanh.

Redes Neurais Convolucionais

As CNNs são uma arquitetura especializada para dados com estrutura espacial, como imagens, que utiliza cálculos matemáticos. As CNN aprendem automaticamente os melhores filtros para extrair as características mais relevantes, ao contrário das redes anteriores, que classificam dados relacionados a características previamente extraídas. O objetivo do treinamento de uma rede CNN é determinar os pesos e vieses dos volumes de convolução. Além disso, são extremamente eficientes no reconhecimento de padrões em imagens, vídeos, áudios, dentre outros.

Algumas das principais camadas utilizadas nas CNN e suas respectivas explicações são:

1. **Camadas convolucionais:** Extraem características das imagens;
2. **Global Average Pooling:** Resume cada mapa de ativação em um valor médio, reduzindo a complexidade e prevenindo o overfitting;

3. **Batch Normalization:** Normaliza as ativações da camada anterior, ajudando a acelerar o treinamento e estabilizar o aprendizado;
4. **Dropout:** Desativa aleatoriamente uma fração dos neurônios durante o treinamento, auxiliando a reduzir o overfitting também;
5. **MaxPooling:** Reduz a dimensão espacial das imagens ao selecionar os valores mais altos em regiões específicas, preservando as informações mais relevantes;
6. **Flatten:** Transforma as saídas multidimensionais em um vetor unidimensional para serem processadas pelas camadas densas; e
7. **Dense:** Realiza o aprendizado final por meio de conexões entre os neurônios.

2.2.3 Algumas aplicações de Aprendizagem de Máquina na literatura

A aprendizagem de máquina encontra amplas aplicações em estudos relacionados a imagens, abrangendo diversas tarefas, como reconhecimento de objetos, detecção facial, segmentação de imagem e classificação de imagens médicas.

Uma aplicação essencial nesse domínio envolve o processamento de imagens médicas, incluindo TC e MRI. Esta aplicação é relacionada a este trabalho, em que algoritmos de aprendizado de máquina são utilizados para detectar e identificar neoplasias cerebrais em imagens médicas.

Para isso, as principais técnicas de AI empregadas são aprendizado de máquina e aprendizado profundo, conforme mencionado na literatura (NIA *et al.*, 2023). Um exemplo ilustrativo da aplicação de AI é a sua utilização no diagnóstico e classificação de uma doença maligna que afeta o sistema nervoso central (LUO *et al.*, 2023). Índia, Estados Unidos e China são os países mais produtivos em termos de publicações científicas no campo desse estudo, conforme indicado pela literatura (HOSSAIN *et al.*, 2023).

É interessante observar a ampla variedade de aplicações para aprendizado de máquina em diversos campos, conforme destacado pela literatura mencionada. Essas aplicações incluem reconstrução de imagens (WANG *et al.*, 2021); estudos relacionados a pesticidas (DAI *et al.*, 2023); identificação de COVID-19 usando imagens de raio-X (KHAN, 2021); identificação de

desnutrição e previsão do índice de massa corporal (IMC)(CHITTATHURU *et al.*, 2021); e, especialmente, classificação de imagens médicas usando RM para identificar doenças (SOLANKI *et al.*, 2023), que é o foco deste trabalho; entre outros estudos.

O aprendizado profundo tornou-se predominante no campo da aprendizado de máquina, especialmente em aplicações como reconstrução profunda de imagens tomográficas (WANG *et al.*, 2021) e estudos relacionados a imagens cerebrais (SCHULZ *et al.*, 2020; KHAN *et al.*, 2022; NAYAK *et al.*, 2022; TANDEL *et al.*, 2019), entre outros.

Em resumo, o Aprendizado de Máquina transformou a maneira de processar e interagir com imagens, com aplicações tanto em reconhecimento de objetos quanto em medicina diagnóstica, dentre outras, proporcionando avanços tecnológicos significativos para o futuro.

2.2.4 Rede Adversária Generativa

As redes Redes Adversárias Generativas, do inglês *Generative Adversarial Networks (GANs)*, consistem em uma abordagem de aumento de dados utilizada no Estado da Arte para melhorar os resultados de classificadores. Ela é constituída pelo gerador, que é responsável por criar imagens tentando se assemelhar a dados reais. Já o discriminador avalia se cada dado gerado é real ou não. O gerador busca confundir o discriminador, enquanto este procura identificar corretamente as amostras falsas. Portanto, ao logo do processo de aprendizado, o gerador aprende a criar dados cada vez mais realistas.

As GANs têm sido utilizadas com frequência em trabalhos científicos envolvendo estudos de MRI, inclusive, a respeito de diferentes tipos de neoplasias cerebrais. Em outras palavras, a geração e classificação de MRI cerebral usando redes GAN com aprendizagem profunda têm sido abordadas na literatura (ALRASHEDY *et al.*, 2022).

A GAN pode ser útil para aumentar o conjunto de dados de treinamento quando este não é suficiente para a aprendizagem (GE *et al.*, 2020). E, como banco de dados com quantidade de dados relativamente suficientes na medicina é raro, são utilizadas, portanto, técnicas como as GANs (AHMAD *et al.*, 2022).

Diversos trabalhos avaliam estudos da GAN utilizando ruído (HAN *et al.*, 2019). Existe estudo que foca no aumento da performance de um sistema utilizando GAN (HAN *et al.*, 2019).

Além disso, as GANs podem ser utilizadas para segmentação de tumores utilizando MRI de cérebro (SILLE *et al.*, 2023; HAMGHALAM; SIMPSON, 2024; E.; SARULADHA, 2020). E também são utilizadas juntamente com técnicas de super resolução para melhorar a resolução de MRI (MOHSEN *et al.*, 2023; ZHOU *et al.*, 2022).

Existem aplicações da GAN em diferentes tipos de imagens. Dentre os diversos tipos de trabalhos, um determinado estudo utilizou a GAN para gerar imagens de cérebro de indivíduos que não têm tumor, devido essa classe não ter número suficiente em relação as demais classes no banco de dados utilizado pela pesquisa (ALRUMIAH *et al.*, 2023).

Já outro estudo aplicou GAN para aumentar os dados de imagem de neoplasias cerebrais (SAHOO *et al.*, 2023). Além disso, uma pesquisa utilizou a GAN em imagens de pacientes diagnosticados com meningioma especificadamente (DEEPAK; AMEER, 2020).

Portanto, em síntese, a GAN é útil para aumentar quantidade de MRI quando o tamanho do conjunto de dados de treinamento não é suficiente para um aprendizado profundo com resultados expressivos, segundo a literatura (GE *et al.*, 2020).

Algumas das principais camadas utilizadas nas CNN para redes geradoras e discriminadoras, que ainda não foram citadas neste trabalho, e suas respectivas explicações são:

1. LeakyReLU: introduz uma pequena inclinação nas saídas negativas da função ReLU;
2. Reshape: reorganiza os dados, preparando-os para as camadas convolucionais subsequentes;
3. Conv2DTranspose: realizam a aumento da resolução espacial das imagens, reconstruindo gradualmente os detalhes a partir de representações de menor dimensão;
4. Camada final Conv2DTranspose: gera a imagem de saída final com o número de canais desejado (neste caso, 3 que é para Vermelho, Verde e Azul, do inglês, *Red, Green and Blue (RGB)*), transformando os mapas de características em uma imagem realista.

MATERIAIS E MÉTODOS

Para o desenvolvimento desta pesquisa, foram utilizados diferentes métodos de classificações de imagens de neoplasias cerebrais (meningioma, glioma e adenomas de hipófise) em apenas uma base de dados, com imagens sem e com aumento de dados. Para isso foram utilizadas e comparadas inicialmente esse tipo de análise nos três cortes (axial, coronal e sagital) e também com apenas o corte axial, pois este obteve melhores resultados, utilizando técnicas de aumento de dados tradicionais, com CNN desenvolvida a partir de uma arquitetura customizada e a partir de redes pré-treinadas (Estratégia 1). Em seguida, utilizando técnicas de classificação em características extraídas por CNNs (Estratégia 2). E, por último, utilizando Transferência de Conhecimento (Estratégia 3). Além disso, foram realizados alguns desses modelos de treinamentos com imagens geradas por Rede Adversária Generativa.

3.1 BANCO DE DADOS

3.1.1 Figshare - 3 Classes

A Tabela 3.1 exibe as características do banco de dados (CHENG, 2017) conforme referenciado em (CHENG *et al.*, 2015) e (CHENG *et al.*, 2016). Os dados dos pacientes foram classificados por três radiologistas. Nesta tabela, é possível observar que o número de pacientes foi 233. O local de coleta de dados ocorreu no Hospital Nanfang, Guangzhou, China, e Hospital Geral, Universidade Médica de Tianjin, China. Esses dados foram obtidos no período de setembro de 2005 a outubro de 2010. Os pixels das imagens são 512 por 512. O tamanho do corte é 0,49 x 0,49 mm². O número de imagens são 3064, sendo 708 de meningioma, 1426 de gliomas e 930 de adenomas de hipófise, logo havia diversas imagens de cada um dos pacientes. Para aquisição dos dados foi avaliado pelo comitê de ética: Comitês de Ética do Hospital Nanfang e Hospital Geral, Universidade Médica de Tianjin. E as imagens foram adquiridas nos cortes axial, sagital e coronal, portanto existem imagens de diferentes cortes de um mesmo indivíduo

no banco de dados (não foram encontradas informações sobre o tipo e a região específica do corte de cada uma das imagens) (CHENG, 2017). Além disso, as MRIs deste banco de dados foram adquiridas com contraste ponderado em T1 (CHENG *et al.*, 2015).

Tabela 3.1: Características do banco de dados (CHENG, 2017) referenciadas em (CHENG *et al.*, 2015).

Características	
Número de pacientes	233
Locais de coleta de dados:	Hospital Nanfang, Guangzhou, China e Hospital Geral, Universidade Médica de Tianjin, China
Pixels das imagens	512 x 512
Tamanho do corte	0,49 x 0,49 mm ²
Número de imagens	3064
Comitê de Ética	(708: meningioma, 1426: gliomas e 930: adenomas de hipófise) Comitês de Ética do Hospital Nanfang e Hospital Geral, Universidade Médica de Tianjin
Tipos de cortes	Axial, sagital e coronal

Limitações

Esta pesquisa apresenta algumas limitações devido ao conjunto de dados escolhido. Por exemplo, há falta de informações sobre os pacientes dos quais as imagens e dados foram extraídos. Além disso, este banco de dados não inclui um grupo de controle, composto por indivíduos saudáveis sem neoplasias cerebrais, o que poderia ser útil para o desenvolvimento de um sistema de diagnóstico.

No entanto, este conjunto de dados foi selecionado devido o significativo número de imagens, sua relevância na literatura existente e no fato de ter sido aprovado por um comitê de ética.

Pré-processamento

Para utilizar essas imagens foram desenvolvidos códigos no Python utilizando a plataforma do Spyder e também do Colab. Sendo que o principal algoritmo de classificação automática de MRI desenvolvido neste trabalho foi registrado no Instituto Nacional da Propriedade Industrial (INPI) (FARIA *et al.*, 2025). Foi utilizado um notebook com as seguintes especificações: sistema operacional Windows 10 de 64 bits, placa de vídeo NVIDIA GeForce de 2 GB, Intel Core I5, 8

GB de memória RAM e, aproximadamente, 1 TB de armazenamento.

Foram separados os dados de cada corte (axial, sagital e coronal) manualmente e cada imagem foi redimensionada para 256x256, utilizando a função `cv2.resize` da biblioteca OpenCV do Python (OPENCV-TEAM, 2024). Isso foi realizado com o intuito de reduzir o custo computacional, visto que mesmo com menor dimensão, as imagens já geravam resultados relevantes, conforme a literatura.

As imagens foram normalizadas a partir de seus valores originais de intensidade. Em seguida, os valores foram reescalados para o intervalo $[0, 255]$ (imagens digitais com 8 bits por canal), no formato `.jpg`, e convertidos para o formato `uint8` (inteiro sem sinal de 8 bits).

Para realizar separação das imagens o nome de cada imagem foi colocado de acordo com o modelo a seguir: `'x1_x2_x3'`. No qual, o primeiro número (`x1`) corresponde ao número de ordem da imagem, o segundo número (`x2`) é o número id do paciente e o terceiro (`x3`) corresponde a classe (sendo 1 para meningioma, 2 para glioma, 3 para adenomas de hipófise).

Cada pixel foi representado em escala de cinza de 8 bits, com valores inteiros variando de 0 (preto) a 255 (branco). As imagens foram redimensionadas em cada estratégia, com o intuito de adequar suas dimensões às exigências do modelo e otimizar o desempenho da classificação. Sendo analisado, além de todos os cortes juntos, cada corte separadamente e selecionado para este trabalho o corte axial, visto que com este foram obtidos os melhores resultados. É importante mencionar que não foram encontradas informações sobre as especificidades dos cortes disponíveis no banco de dados.

Os dados foram testados com o intuito de verificar se não ocorria vazamento de dados, ou seja, imagens de um mesmo indivíduo em grupos diferentes. Para isso, foi desenvolvido um algoritmo que extrai as informações dos números ids das imagens. Em seguida, com estes valores, foi analisado se existem imagens de um mesmo paciente em grupo diferentes com uma função do Python, que verifica se há interseção entre os dados dos grupos de teste e de treinamento. Como não obteve interseção, logo confirmou-se que não havia vazamento de dados.

Além disso, separar previamente os dados de treinamento e validação causava *overfitting* nos resultados obtidos, logo optou-se unir os dados da pasta de treinamento e de validação em

uma só e o sistema separar automaticamente os dados em treinamento (80%) e em validação (20%) durante as execuções dos códigos relacionados a análises do corte axial.

3.2 CNN UTILIZANDO AUMENTO DE DADOS - ESTRATÉGIA 1

Nesta estratégia, aplicou-se normalização dos dados (escala de 0 a 1). Além disso, aproximadamente 80% dos dados foram usados para treinamento (20% dos quais foram usados para validação) e 20% para teste. O número de épocas foi definido como 100. Nesta etapa, o k-fold não foi utilizado porque o número de imagens no grupo axial é relativamente baixo para este tipo de aplicação. As camadas da rede convolucional foram definidas após vários testes que determinaram as camadas que alcançaram os melhores resultados. O tamanho do lote foi definido como 32, para o caso axial e 100 para o banco total, adaptando-se a quantidade de imagens de cada caso; além de ser definida a escala RGB.

Nesta etapa, o treinamento do modelo segue uma lógica de retomada automática a partir do último ponto salvo. Inicialmente, o modelo é carregado de um arquivo salvo anteriormente ou inicializado, caso não exista. Durante o treinamento são salvos o progresso do modelo e atualizado o histórico acumulado com acurácia e perda em treino e validação. O treinamento é realizado com base em geradores de dados, por um número definido de épocas, e pode ser retomado a partir da última época concluída, evitando reinício do processo em caso de interrupções.

Para ampliar a variabilidade do conjunto de treinamento e reduzir o risco de *overfitting*, foi realizado dois tipos de aumento de dados: flip horizontal e adição de ruído gaussiano. O flip horizontal consiste na inversão dos pixels da imagem no eixo horizontal, gerando uma nova amostra que preserva as características estruturais da lesão, mas altera sua orientação espacial. Já o ruído gaussiano foi adicionado para simular variações de aquisição e pequenas imperfeições inerentes a exames reais de ressonância magnética. Para isso, foi gerado um ruído aleatório com distribuição normal de média zero e desvio padrão igual a 40, somado aos valores originais dos pixels e posteriormente limitado ao intervalo $[0, 255]$, garantindo a integridade dos níveis de intensidade. Além disso, para aumentar os dados, na etapa de treino, o tamanho da matriz de treinamento foi duplicado durante a etapa de aumento de dados.

As camadas das redes convolucionais foram definidas após alguns testes quando verificou-se que as camadas escolhidas obtiveram melhores resultados, e, também, relevantes segundo a literatura. Logo, a seguir são apresentadas as camadas das redes definidas para cada etapa desta estratégia.

3.2.1 Todos os três cortes

Nesta etapa, as camadas convolucionais foram obtidas conforme imagem da Figura 3.1 relacionada ao modelo de CNN customizado utilizando imagens dos três cortes. Neste caso, a rede é composta por três sequências de camadas convolucionais, *maxpooling* e *dropout*, além de uma camada *flatten*, *dense*, *dropout* e *dense*, respectivamente.

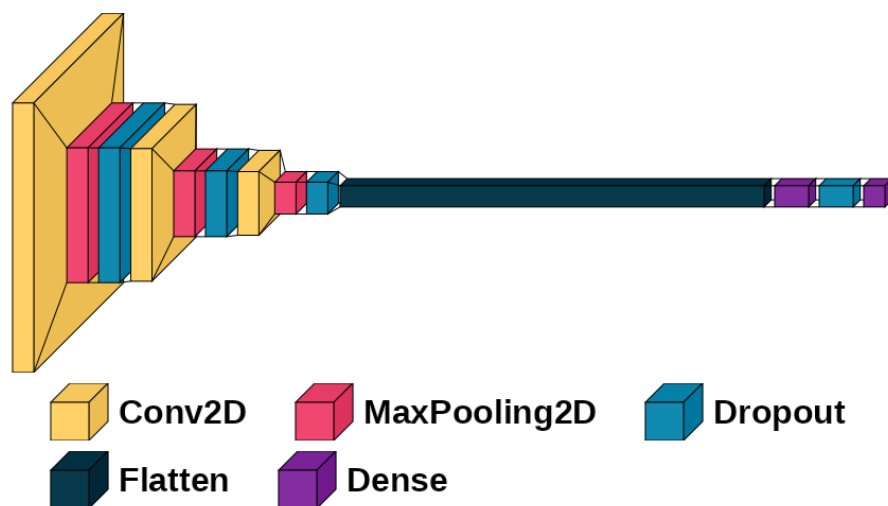


Figura 3.1: Diagrama de blocos das camadas convolucionais da rede CNN utilizando imagens dos três cortes. Esta rede é composta por três sequências de camadas convolucionais, *maxpooling* e *dropout*, além de uma camada *flatten*, *dense*, *dropout* e *dense*, respectivamente.

Além disso, utilizando o modelo de CNN pré-treinada (VGG16), as camadas convolucionais foram obtidas conforme imagem da Figura 3.2. Neste caso, a rede é composta por uma sequência de camadas convolucionais, *batch normalization*, *maxpooling*, *global average pooling*, *dropout* e *dense*, respectivamente.

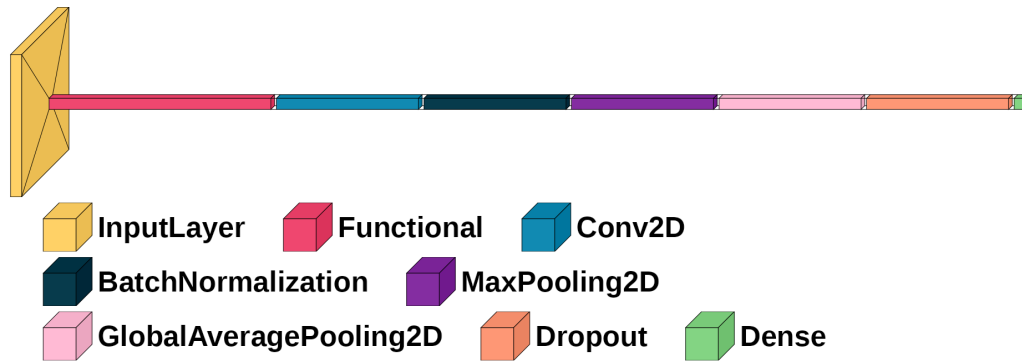


Figura 3.2: Diagrama de blocos das etapas das camadas convolucionais da rede CNN pré-treinada (VGG16) utilizando imagens dos três diferentes cortes. Esta rede é composta por uma sequência de camadas convolucionais, *batch normalization*, *maxpooling*, *global average pooling*, *dropout* e *dense*, respectivamente.

3.2.2 Apenas corte axial

Nesta etapa, as camadas convolucionais da rede customizada foram projetadas conforme o diagrama mostrado na Figura 3.3, que corresponde ao modelo CNN utilizando apenas cortes axiais, pois estes obtiveram melhores resultados. Neste caso, a rede é composta por três sequências de camadas convolucionais e *maxpooling*, além de uma camada *global average pooling*, *dense*, *dropout* e *dense*, respectivamente.

Além disso, utilizando o modelo de CNN pré-treinada (VGG16), as camadas convolucionais foram obtidas conforme imagem da Figura 3.4. Neste caso, a rede é composta por uma sequência de *global average*, *dropout* e *dense*, respectivamente.

3.3 EXTRAÇÃO DE CARACTERÍSTICAS UTILIZANDO REDES NEURAS CONVOLUCIONAIS - ESTRATÉGIA 2

Nesta etapa, para extração de características foram utilizadas as CNNs, com os seguintes modelos, DenseNet121, MobileNet, EfficientNetV2 B0, Inception V3 e Xception. Essas abordagens possuem as quantidades de características extraídas conforme valores indicados na Tabela 3.2.

De forma geral, as camadas dessas redes extraem padrões visuais básicos, como bordas e texturas simples; além disso, capturam formas e texturas mais complexas; e extraem padrões

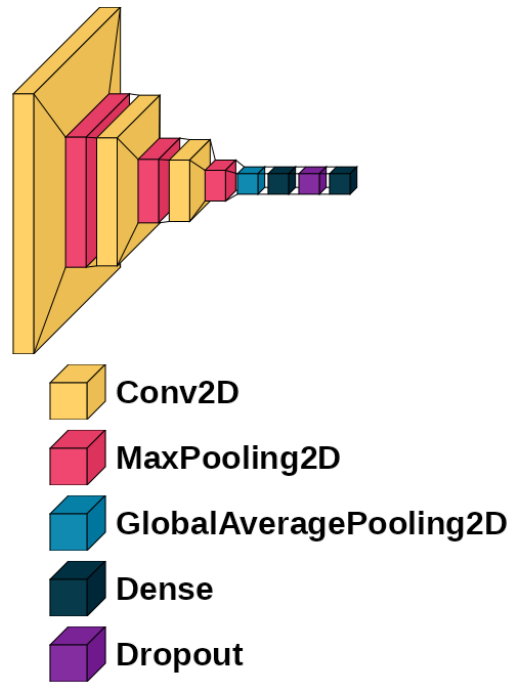


Figura 3.3: Diagrama de blocos das camadas convolucionais no modelo CNN utilizando apenas cortes axiais. Esta rede é composta por três sequências de camadas convolucionais e *maxpooling*, além de uma camada *global average pooling*, *dense*, *dropout* e *dense*, respectivamente.

Tabela 3.2: Quantidade de características (que foram divididas em treinamento e teste) extraídas por cada arquitetura de aprendizado profundo.

Arquitetura	Quantidade de características
DenseNet121	1024
MobileNet	1024
EfficientNetV2 B0	1280
Inception V3	2048
Xception	2048

anatômicos e variações de intensidade relevantes para diferenciar tecidos saudáveis de regiões com neoplasias. Assim, os vetores finais de características (1024 a 2048 dimensões) funcionam como uma representação compacta das imagens de ressonância, permitindo os classificadores distinguir os diferentes tipos de tumores cerebrais. Depois, para cada modelo, foram reduzidas as dimensionalidades das características extraídas para 256 características, utilizando *Principal Component Analysis (PCA)*. Isso foi realizado nos dados de teste e de treinamento, em cada modelo, tornando os dados ainda mais compactos.

Em seguida, estas características foram utilizadas nos classificadores apresentados na Tabela 3.3 utilizando imagens apenas do corte axial e relacionadas a três classes (meningioma,




Figura 3.4: Diagrama de blocos das camadas convolucionais no modelo da rede CNN pré-treinada (VGG16) utilizando apenas cortes axiais. Esta rede é composta por uma sequência de *global average*, *dropout* e *dense*, respectivamente.

glioma e adenoma de hipófise). Nesta etapa, foram realizadas 10 iterações, utilizando o método k-fold, para evitar a ocorrência de *overfitting*, adaptada para apenas os dados de treinamento, os dados de testes foram separados e são fixos. Além disso, nesta etapa, foram utilizados três canais, em outras palavras, definida a escala RGB.

Tabela 3.3: Classificadores e seus parâmetros utilizados neste trabalho na Estratégia 2. Todos do pacote da scikit-learn (PEDREGOSA *et al.*, 2011).

Classificadores	
C0	Logistic Regression: LogisticRegression(penalty='none', solver='newton-cg')
C1	K Nearest Neighbors (KNN): KNeighborsClassifier()
C2	Decision Tree Classifier: DecisionTreeClassifier()
C3	SVM: svm.SVC(kernel="rbf")
C4	Stochastic Gradient Descent: SGDClassifier(loss="hinge", penalty="l2", max_iter=5)
C5	Random Forest: RandomForestClassifier(max_depth=2, random_state=0)
C6	Gaussian Naive Bayes: GaussianNB()
C7	Quadratic Discriminant Analysis (QDA): QuadraticDiscriminantAnalysis()
C8	MLP: MLPClassifier(alpha=1, max_iter=1000)
C9	Bagging Classifier: base_classifier=DecisionTreeClassifier(random_state=42) BaggingClassifier(base_estimator=base_classifier, n_estimators=10,random_state=42)
C10	Extra Trees Classifier: ExtraTreesClassifier(n_estimators=200, random_state=42)
C11	Linear Discriminant Analysis (LDA): LinearDiscriminantAnalysis().

3.4 TRANSFERÊNCIA DE CONHECIMENTO - ESTRATÉGIA 3

Além disso, técnicas de rede pré-treinada, conhecidas como *Transfer Learning*, foram empregadas. Estas consistem em estratégias de classificação em aprendizado de máquina, a qual aproveita o conhecimento adquirido por um modelo pré-treinado em uma determinada tarefa com o intuito de melhorar o desempenho em uma aplicação diferente. Além disso, tamanho de lote de 32, sem aumento de dados e três canais, ou seja, definida a escala RGB, pois estes parâmetros obtiveram os melhores resultados encontrados.

Nesta etapa, as camadas convolucionais foram projetadas conforme mostrado na Figura 3.5, correspondendo ao modelo de *transfer learning*. Neste caso, a rede é composta por camada *global average pooling*, duas sequências de *dense*, *batch normalization* e *dropout*, além de uma camada *dense*, respectivamente.



Figura 3.5: Diagrama de blocos das camadas convolucionais no modelo de *transfer learning* da CNN utilizando apenas cortes axiais. Esta rede é composta por camada *global average pooling*, duas sequências de *dense*, *batch normalization* e *dropout*, além de uma camada *dense*, respectivamente.

A Tabela 3.4 apresenta as quantidades de imagens de cada classe para o conjunto de teste, treinamento e validação, respectivamente, das imagens do grupo de corte axial, sagital e coronal para comparação do uso de transferência de conhecimento (Estratégia 3). 80% dos dados foram separados para treinamento (20% das imagens de treinamento foram separadas para validação) e 20% para teste. Para essa separação foram utilizadas informações dos nomes das imagens extraídas, sobretudo o número id. O tamanho da imagem definido como 256x256 e 500 épocas.

Utilizando o corte axial, vários modelos foram selecionados, incluindo DenseNet121, MobileNet, EfficientNetV2 B0, Inception V3 e Xception, pois estes são modelos comumente utilizados na literatura. A Tabela 3.5 apresenta as quantidades de imagens de cada classe para o conjunto de teste, treinamento e validação, respectivamente, das imagens do grupo de corte axial (que obteve melhores resultados) para o uso de transferência de conhecimento (Estratégia 3). Foi observado que separar os dados de treinamento e validação causava *overfitting* nos resultados.

Tabela 3.4: Quantidade de imagens de teste de cada classe, sendo, classe 1 para tumor do tipo meningioma, 2 para glioma, 3 para adenomas de hipófise. Aproximadamente, 80% para treinamento (desses, 20% foi separado para validação) e 20% para teste de cada corte (axial, sagital e coronal). Estratégia 3.

	Teste	Treinamento	Validação
Axial:			
Classe 1 (meningioma)	37	139	31
Classe 2 (glioma)	99	314	83
Classe 3 (adenomas de hipófise)	49	194	98
Sagital:			
Classe 1 (meningioma)	61	159	48
Classe 2 (glioma)	65	213	44
Classe 3 (adenomas de hipófise)	83	282	72
Coronal:			
Classe 1 (meningioma)	53	147	32
Classe 2 (glioma)	103	296	80
Classe 3 (adenomas de hipófise)	61	201	50

Portanto, as pastas de dados de treinamento e validação foram mescladas nos algoritmos de *transfer learning*. Para o grupo axial, 80% dos dados foram separados para treinamento (10% das imagens de treinamento foram separadas para validação) e 20% dos dados foram utilizados para teste. Para essa separação foram utilizadas informações dos nomes das imagens extraídas, sobretudo o número id. Além disso, foram utilizadas 140 épocas, com dimensões de imagem de 224x224 pixels.

Tabela 3.5: Quantidade de imagens de teste de cada classe, sendo, classe 1 para tumor do tipo meningioma, 2 para glioma, 3 para adenomas de hipófise. Aproximadamente, 80% para treinamento (desses, 10% foi separado para validação) e 20% para teste. Estratégia 3.

	Teste	Treinamento	Validação
Axial:			
Classe 1 (meningioma)	37	155	15
Classe 2 (glioma)	99	354	43
Classe 3 (adenomas de hipófise)	49	219	23

3.5 REDE ADVERSÁRIA GENERATIVA

Para essa etapa, foram utilizados os seguintes parâmetros que obtiveram melhores resultados, sendo 3000 épocas, tamanho do *batch* de 32, 3 canais, dimensão do ruído de 100, tamanho da imagem de 256 x 256, com as seguintes camadas para gerador e discriminador, respectiva-

Tabela 3.6: Quantidade de imagens de teste, treinamento e validação de cada classe, sendo, classe 1 para meningioma, 2 para glioma, 3 para adenomas de hipófise para a abordagem da GAN. Das imagens geradas pela GAN, 20% foram utilizadas para validação e 80% para treinamento.

	Teste	Treinamento	Validação
Axial:			
Classe 1 (meningioma)	37	454	113
Classe 2 (glioma)	99	766	191
Classe 3 (adenomas de hipófise)	49	648	162

3.6 MÉTRICAS UTILIZADAS NA AVALIAÇÃO DE DESEMPENHO

Primeiramente, para calcular as métricas de avaliação de desempenho, a matriz de confusão foi computada. A matriz segue o modelo

$$\begin{bmatrix} V_P[1] & F_P[2] & F_P[3] \\ F_P[1] & V_P[2] & F_P[3] \\ F_P[1] & F_P[2] & V_P[3] \end{bmatrix}$$

onde as linhas representam as classes reais e as colunas representam as classes previstas, portanto, $V_P[1]$ representa a quantidade de verdadeiros positivos para a classe 1, $V_P[2]$ representa a quantidade de verdadeiros positivos para a classe 2, $V_P[3]$ representa a quantidade de verdadeiros positivos para a classe 3, $F_P[1]$ representa a quantidade de falsos positivos para a classe 1, $F_P[2]$ representa a quantidade de falsos positivos para a classe 2, e $F_P[3]$ representa a quantidade de falsos positivos para a classe 3.

Foi desenvolvido um algoritmo para encontrar os valores de V_P , F_P e F_n , quantidade de verdadeiros positivos, falsos positivos e falsos negativos, respectivamente, conforme mostrado no diagrama da Figura 3.8. A primeira etapa é inicializar as variáveis com zeros. Depois ocorre um *loop* que verifica todo o vetor de teste e um novo *loop* para o número de classes. Se o valor real for igual o predito, incrementa em uma variável V_P da classe correspondente. Caso contrário, incrementa F_P e F_n para cada classe correspondente.

A principal métrica de desempenho utilizada neste trabalho foi a acurácia. Ela é calculada com base em

$$Ac = \frac{\sum_{c=1}^3 V_P[c]}{\sum_{c=1}^3 (V_P[c] + F_P[c])}, \quad (3.1)$$

a qual é empregada para analisar um problema com três classes, onde V_P corresponde aos

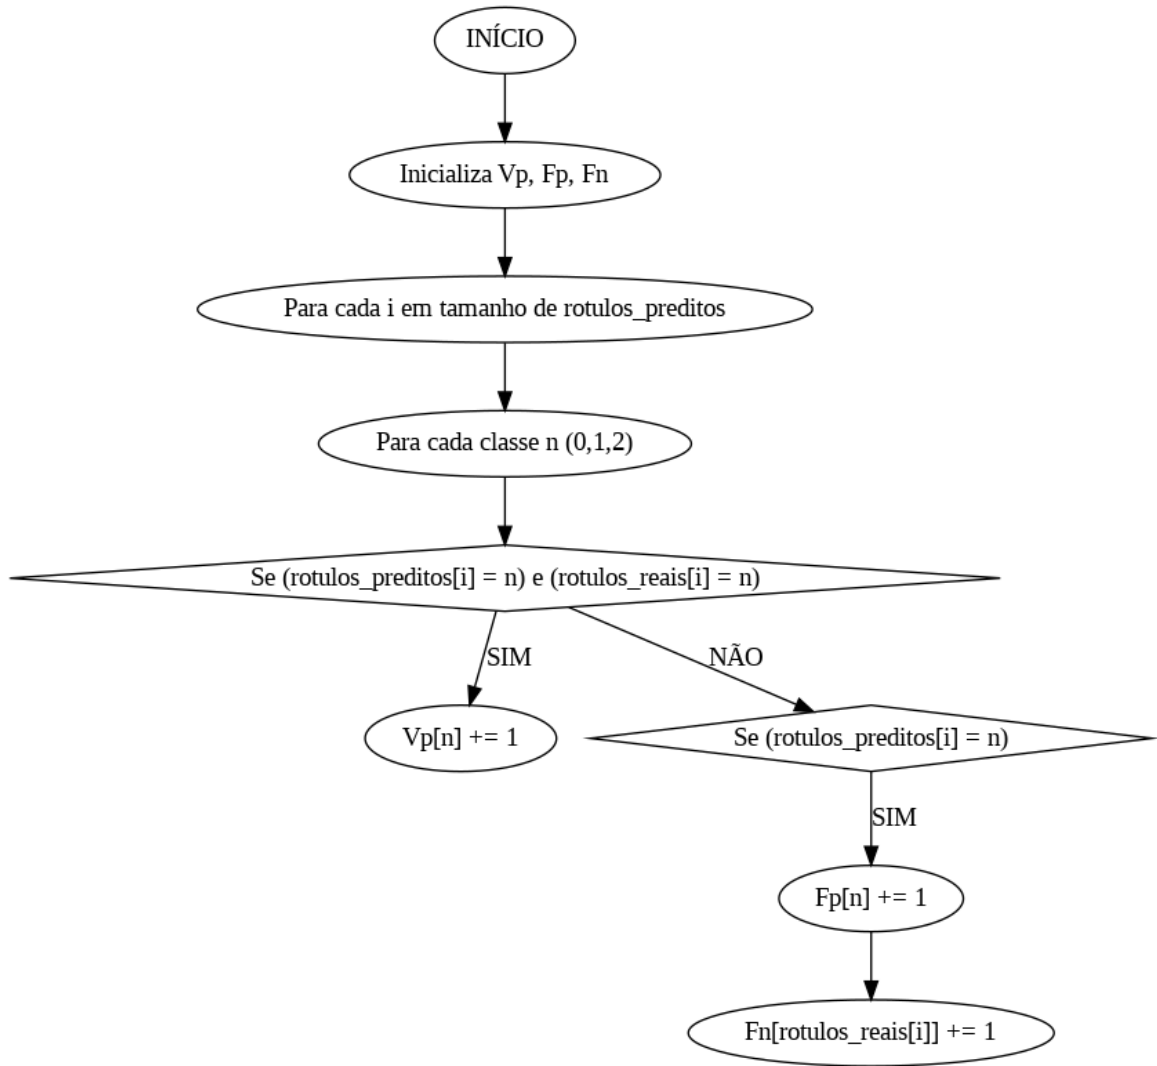


Figura 3.8: Diagrama da função desenvolvida para cálculo de V_P , F_P e F_n .

verdadeiros positivos e F_P representa os falsos positivos (amostras classificadas incorretamente como classe c quando na verdade pertencem a outras classes), e c corresponde a cada classe.

Além disso, a precisão para a classe 1, classe 2 e classe 3 é calculada conforme, respectivamente,

$$P[1] = \frac{V_P[1]}{V_P[1] + F_P[1]}, \quad (3.2)$$

$$P[2] = \frac{V_P[2]}{V_P[2] + F_P[2]} \quad (3.3)$$

e

$$P[3] = \frac{V_P[3]}{V_P[3] + F_P[3]}. \quad (3.4)$$

$$P[c] = \frac{V_P[c]}{V_P[c] + F_P[c]} \quad (3.5)$$

resume o cálculo da precisão para todas as três classes. E

$$P = \frac{\sum_{c=1}^3 P[c]}{3} \quad (3.6)$$

calcula a média da precisão para todas as classes.

As equações

$$S[1] = \frac{V_P[1]}{V_P[1] + F_N[1]}, \quad (3.7)$$

$$S[2] = \frac{V_P[2]}{V_P[2] + F_N[2]} \quad (3.8)$$

e

$$S[3] = \frac{V_P[3]}{V_P[3] + F_N[3]}, \quad (3.9)$$

calculam sensibilidade, do inglês *recall*, para cada classe, onde $F_N[c]$ representa os falsos negativos para a classe c , correspondendo a amostras que foram incorretamente classificadas como pertencentes a outras classes que não a c quando, na verdade, pertencem a essa classe.

$$S[c] = \frac{V_P[c]}{V_P[c] + F_N[c]} \quad (3.10)$$

fornece um resumo dos valores de sensibilidade. Em seguida, a média de sensibilidade entre diferentes classes é calculada, conforme

$$S = \frac{\sum_{c=1}^3 R[c]}{3}. \quad (3.11)$$

O F-score é calculado com base nos valores de precisão e sensibilidade, ou seja,

$$F[c] = \frac{2P[c]S[c]}{P[c] + S[c]}. \quad (3.12)$$

Em seguida, a média de medida-F entre diferentes classes é calculada, conforme

$$F = \frac{\sum_{c=1}^3 F[c]}{3}. \quad (3.13)$$

Por fim, as médias da acurácia, precisão, sensibilidade e medida-F são calculadas. Esses resultados são então multiplicados por 100 para expressá-los em porcentagem.

Nesta pesquisa, foram selecionadas as métricas de acurácia, precisão, sensibilidade e medida-F para avaliar o desempenho dos modelos de classificação. Essas métricas são comumente

utilizadas em conjunto nas pesquisas científicas por permitirem análise do desempenho. Entretanto, essas métricas analisadas isoladamente podem ocasionar informações equivocadas, visto que não refletem o desempenho real de maneira isoladas. Dessa forma, a combinação dessas métricas permite uma avaliação mais confiável e real do modelo, sobretudo relacionado a área médica, para evitar que ocorra um falso positivo ou falso negativo em diagnósticos.

RESULTADOS E DISCUSSÃO

4.1 TÉCNICAS DE AUMENTO DE DADOS - ESTRATÉGIA 1

A Tabela 4.1 apresenta os resultados das medidas dos dados de teste de desempenho de CNN com e sem aumento de dados, separados em análises de imagens de todos os cortes e com apenas o corte axial.

O gráfico da Figura 4.1 apresenta os resultados de treinamento e validação obtidos pela CNN utilizando imagens de todos os cortes, sem aumento de dados. Em ‘(a)’ está a acurácia em função da época e em ‘(b)’ está a função de perda em função da época.




Figura 4.1: Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN utilizando imagens de todos os cortes, sem aumento de dados. Em ‘(a)’ está a acurácia em função da época e em ‘(b)’ está a função de perda em função da época.

Além disso, os gráficos da Figura 4.2 apresentam os resultados de treinamento e validação obtidos pela CNN pré-treinada utilizando imagens de todos os cortes, sem aumento de dados.

E os gráficos nas Figuras 4.3, 4.4 e 4.5 apresentam os resultados de treinamento e validação

Tabela 4.1: Métricas de desempenho da classificação de neoplasias cerebrais a partir de MRI utilizando CNNs customizada e com redes pré-treinadas, inserindo em alguns casos o aumento de dados, além disso, com todos os cortes e também com apenas o corte axial.

Método	Acurácia (%)	Precisão (%)	Sensibilidade (%)	Medida-F (%)
Todos os cortes				
Customizada, Sem aumento de dados	77,9	77,0	74,7	75,8
Pré-treinada, Sem aumento de dados	88,7	90,6	85,5	88,0
Corte Axial				
Customizada, Sem aumento de dados	85,8	82,2	81,6	81,9
Customizada, Flip	85,2	88,0	77,9	82,6
Customizada, Flip + Ruído	85,2	87,4	76,5	81,6
Pré-treinada, Sem aumento de dados	85,2	81,6	80,9	81,2
Pré-treinada, Flip	85,8	83,8	82,4	83,1
Pré-treinada, Flip + Ruído	88,4	84,3	84,9	84,6




Figura 4.2: Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN pré-treinada utilizando imagens de todos os cortes, sem aumento de dados. Em ‘(a)’ está a acurácia em função da época e em ‘(b)’ está a função de perda em função da época.

obtidos pela CNN utilizando apenas o corte axial, sem aumento de dados; com flip; e com flip e ruído, respectivamente.

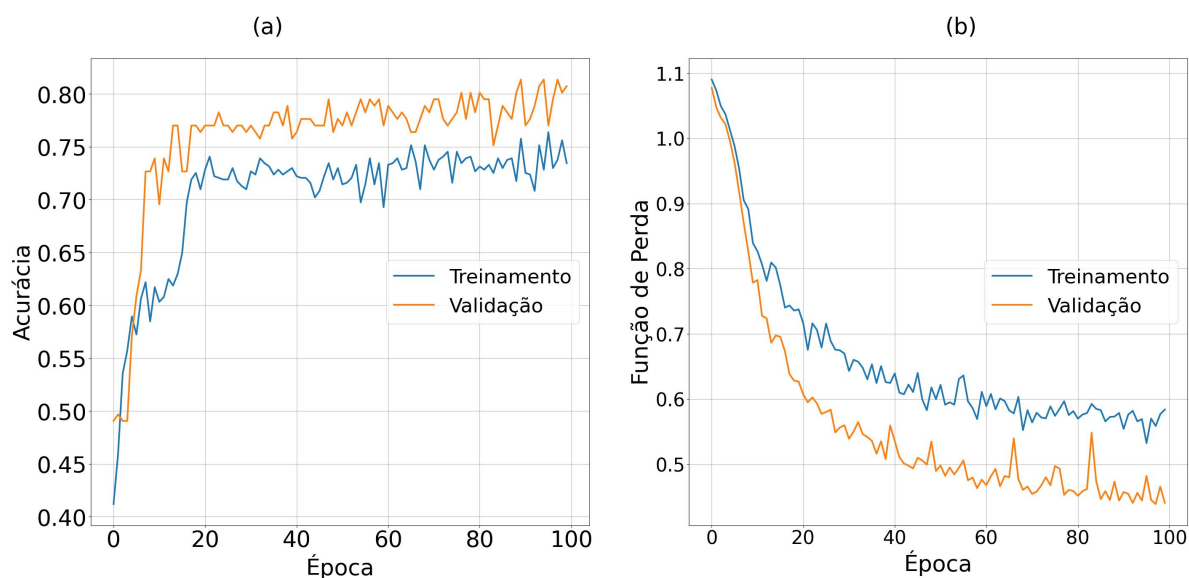


Figura 4.3: Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN utilizando apenas o corte axial, sem aumento de dados. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época.

E, por fim, os gráficos nas Figuras 4.6, 4.7, 4.8 apresentam os resultados de treinamento e validação obtidos pela CNN pré-treinada utilizando apenas o corte axial, sem aumento de dados; com flip; e com flip e ruído, respectivamente.




Figura 4.4: Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN utilizando apenas o corte axial, com aumento de dados utilizando flip. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época.




Figura 4.5: Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN utilizando apenas o corte axial, com aumento de dados utilizando flip e ruído. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época.

Diante desses resultados, é possível verificar no gráfico da Figura 4.1 que tanto a acurácia como a função de perda possuem oscilações. Além disso, os valores de acurácia não estão em uma faixa de valores relevantes comparados aos resultados da literatura (Seção 4.5), estão com valores de acurácia abaixo de 85%.

Na imagem da Figura 4.2, verifica-se que os resultados alcançados foram inferiores ao caso




Figura 4.6: Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN pré-treinada utilizando apenas o corte axial, sem aumento de dados. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época.

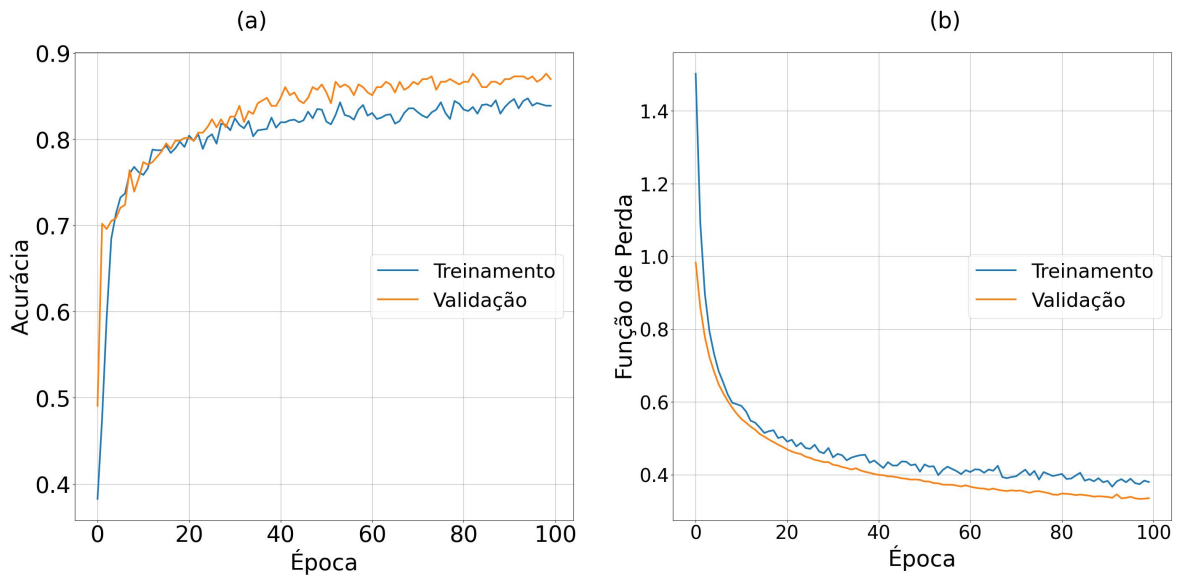


Figura 4.7: Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN pré-treinada utilizando apenas o corte axial, com aumento de dados utilizando flip. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época.

da CNN utilizada desenvolvida a partir de uma arquitetura customizada. Pois ocorreu um distanciamento relevante entre as curvas de treinamento e validação configurando provavelmente em *overfitting*. Isto ocorre quando o modelo aprende muito bem as informações do conjunto de treinamento, mas não generaliza bem para dados da validação, quando a complexidade dos modelos utilizados é superior ao necessário para esta determinada aplicação.




Figura 4.8: Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN pré-treinada utilizando apenas o corte axial, com aumento de dados utilizando flip e ruído. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época.

Já nos gráficos nas Figuras 4.3, 4.4 e 4.5 (apenas imagens axiais) verifica-se que a ocorrência de provavelmente *underfitting*, quando a curva de treinamento está abaixo da curva de validação com uma distância expressiva. Isto ocorre quando o modelo é muito simples ou mal treinado. E os gráficos nas Figuras 4.6, 4.7, 4.8 apresentam resultados com menor *underfitting* em comparação com todos os anteriores, sobretudo os que possuem aumento de dados (ruído e flip).

Portanto, observou-se que os resultados obtidos utilizando análises apenas das imagens do corte axial, em geral, foram melhores do que analisando todos os cortes juntos. Além disso, a rede com aumento de dados, utilizando flip e ruído e utilizando apenas o corte axial, desenvolvida a partir de uma arquitetura pré-treinada, alcançou o melhor resultado com acurácia(%): 88,4; precisão(%): 84,3; sensibilidade(%): 84,9; e f-score(%): 84,6, conforme mostrado na Tabela 4.1 e no gráfico da Figura 4.8.

Conclui-se que os aumentos de dados utilizados nesta pesquisa, nesta etapa, utilizando essas técnicas de aumento de dados, apresentadas nesta Seção 4.1, não melhoraram os resultados de acordo com a metodologia aplicada em comparação com resultados obtidos na literatura, conforme apresentado na Seção 4.5.

4.2 CLASSIFICAÇÃO DE CARACTERÍSTICAS RELACIONADAS A EXTRAÇÃO UTILIZANDO CNN (APENAS CORTE AXIAL) - ESTRATÉGIA 2

As Tabelas 4.2 até 4.8 apresentam as métricas de desempenho médias para classificações do banco de dados utilizando como entradas as características extraídas utilizando CNN, DenseNet121, MobileNet, EfficientNetV2 B0, Inception V3, Xception, respectivamente. Cada tabela apresenta os resultados de desempenho dos classificadores, na ordem decrescente de acurácia.

Nesta etapa, para evitar ocorrência de *overfitting*, foi utilizado o método *k-fold*, com k igual a 10, utilizado frequentemente na literatura. Além disso, verifica-se que os maiores resultados foram utilizando as características extraídas com MobileNet, passando pelo processo de redução de dimensionalidade; e classificadas utilizando MLP, atingindo 94% de acurácia. Além disso, MLP foi o modelo de classificador que obteve melhores desempenhos na maioria dos resultados obtidos pelos diferentes modelos de extração de características.

Para comparar os casos sem redução de dimensão e com redução de dimensão, foram inseridas as Tabelas 4.2 e 4.3, verificou-se que a redução de dimensão não gerou resultados com diferenças relevantes. Entretanto, nestes exemplos, do modelo DenseNet121, o tempo computacional total do treinamento e teste, reduziu de 4 minutos e 6 segundos para 1 minuto e 14 segundos, para o caso com redução de dimensão. Essa redução do custo computacional pode ser vantajosa, por exemplo, facilitando os treinamentos dos sistemas classificadores, otimizando estudos relacionados; além do otimizar o desenvolvimento de sistemas embarcados; e economizar energia necessária para uso dessas aplicações. Da mesma forma, ocorreu com os resultados de Xception (Tabelas 4.7 e 4.8), em que o tempo total foi reduzido de 7 minutos e 12 segundos para 1 minuto e 19 segundos para o exemplo com redução de dimensão. Portanto, as demais tabelas apresentam resultados obtidos com a redução de dimensão.

É importante acrescentar que Regressão Logística foi o modelo de classificador com maior custo computacional, dentre os demais. E, observa-se também, que o tempo total foi obtido, sobretudo pelo tempo das classificações.

Tabela 4.2: Métricas de desempenho médias para classificações utilizando DenseNet121 para extrair as características. Classificação sem redução de dimensão. **Tempo total de execução (treinamento e teste):** 4 minutos e 6 segundos.

Classificador	Acurácia(%)	Precisão(%)	Sensibilidade(%)	Medida-F(%)	Tempo (s)
MLP	89,4	86,6	86,9	86,7	52,4
Logistic Regression	87,7	83,9	84,9	84,4	125,0
Linear Discriminant Analysis	84,5	81,2	79,4	80,3	5,69
SVM	88,2	85,1	85,5	85,3	4,4
SGDC	88,6	85,8	86,2	86,0	1,2
K Neighbors Classifier	81,3	76,2	77,2	76,7	0,6
Bagging Classifier	91,7	90,3	88,9	89,6	34,2
Extra Trees Classifier	91,2	91,5	87,1	89,3	7,1
Decision Tree Classifier	87,4	85,4	83,9	84,6	6,6
Gaussian NB	82,9	78,5	80,9	79,7	0,5
Random Forest Classifier	82,6	88,9	72,1	79,6	6,2
Quadratic Discriminant Analysis	54,7	50,4	50,4	50,4	1,93

Tabela 4.3: Métricas de desempenho médias para classificações utilizando DenseNet121 para extrair as características. Classificação com redução de dimensão. **Tempo total de execução (treinamento e teste):** 1 minuto e 14 segundos.

Classificador	Acurácia(%)	Precisão(%)	Sensibilidade(%)	Medida-F(%)	Tempo (s)
MLP	88,9	85,5	86,7	86,1	15,1
Logistic Regression	88,5	84,7	86,0	85,4	33,1
Linear Discriminant Analysis	91,2	88,8	88,5	88,6	1,3
SVM	87,7	84,8	84,3	84,6	2,4
SGDC	87,4	85,4	84,3	84,8	0,5
K Neighbors Classifier	81,0	75,7	76,6	76,1	0,2
Bagging Classifier	76,9	71,6	71,9	71,8	10,6
Extra Trees Classifier	76,1	79,2	63,6	70,5	5,2
Decision Tree Classifier	71,8	65,6	65,9	65,8	2,1
Gaussian NB	74,5	70,1	73,0	71,5	0,2
Random Forest Classifier	54,9	–	35,1	–	3,2
Quadratic Discriminant Analysis	53,5	–	33,3	–	0,60

Tabela 4.4: Métricas de desempenho médias para classificações utilizando MobileNet para extrair as características. Classificação com redução de dimensão.

Classificador	Acurácia(%)	Precisão(%)	Sensibilidade(%)	Medida-F(%)
MLP	94,0	93,0	91,9	92,4
Logistic Regression	92,9	90,9	91,1	91,0
Linear Discriminant Analysis	92,7	91,2	90,5	90,9
SVM	92,7	90,9	90,4	90,6
SGDC	91,1	90,9	87,7	89,3
K Neighbors Classifier	87,7	84,6	84,8	84,7
Bagging Classifier	82,9	77,5	78,7	78,1
Extra Trees Classifier	81,1	85,4	69,8	76,8
Decision Tree Classifier	79,0	73,8	74,3	74,1
Gaussian NB	78,6	77,5	72,1	74,7
Random Forest Classifier	54,5	–	34,6	–
Quadratic Discriminant Analysis	53,5	–	33,3	–

Tabela 4.5: Métricas de desempenho médias para classificações utilizando EfficientNet V2 B0 para extrair as características. Classificação com redução de dimensão.

Classificador	Acurácia(%)	Precisão(%)	Sensibilidade(%)	Medida-F(%)
MLP	87,1	83,6	84,0	83,8
Logistic Regression	89,0	86,0	87,2	86,6
Linear Discriminant Analysis	82,4	78,2	79,2	78,7
SVM	85,4	83,3	81,1	82,2
SGDC	87,2	84,1	84,9	84,5
K Neighbors Classifier	79,0	74,9	75,0	74,9
Bagging Classifier	73,4	66,8	66,7	66,7
Extra Trees Classifier	77,7	82,5	65,4	72,9
Decision Tree Classifier	67,6	62,5	63,0	62,7
Gaussian NB	60,1	56,0	56,6	56,3
Random Forest Classifier	59,2	–	40,6	–
Quadratic Discriminant Analysis	53,5	–	33,3	–

Tabela 4.6: Métricas de desempenho médias para classificações utilizando Inception V3 para extrair as características. Classificação com redução de dimensão.

Classificador	Acurácia(%)	Precisão(%)	Sensibilidade(%)	Medida-F(%)
MLP	93,5	92,2	92,3	92,2
Logistic Regression	91,8	90,4	90,2	90,3
Linear Discriminant Analysis	92,8	91,0	92,3	91,6
SVM	91,7	90,1	89,4	89,8
SGDC	89,2	88,3	85,8	87,0
K Neighbors Classifier	85,2	83,2	81,4	82,3
Bagging Classifier	80,3	77,8	75,4	76,6
Extra Trees Classifier	76,1	86,1	62,7	72,6
Decision Tree Classifier	75,3	71,3	71,2	71,3
Gaussian NB	70,8	67,3	64,7	66,0
Random Forest Classifier	55,3	–	35,6	–
Quadratic Discriminant Analysis	53,5	–	33,3	–

Tabela 4.7: Comparação de desempenho médio dos classificadores utilizando Xception para extrair as características. Classificação sem redução de dimensão. Tempo de execução de cada classificador em segundos. **Tempo total de execução (treinamento e teste): 7 minutos e 12 segundos.**

Classificador	Acurácia(%)	Precisão(%)	Sensibilidade(%)	Medida-F(%)	Tempo (s)
MLP	89,0	87,5	85,6	86,5	68,3
Logistic Regression	88,2	85,8	84,5	85,1	248,4
Linear Discriminant Analysis	87,1	84,5	85,2	84,9	6,1
SVM	86,4	84,9	83,1	84,0	10,0
SGDC	88,1	86,4	84,6	85,5	2,2
K Neighbors Classifier	86,0	82,7	83,6	83,1	1,0
Bagging Classifier	82,3	80,7	79,0	79,9	61,8
Extra Trees Classifier	85,3	85,4	79,7	82,4	11,3
Decision Tree Classifier	75,5	72,9	72,4	72,6	12,4
Gaussian NB	82,2	78,0	79,1	78,6	0,8
Random Forest Classifier	75,8	-	61,4	-	7,0
Quadratic Discriminant Analysis	47,9	41,5	41,3	41,4	3,3

Tabela 4.8: Comparação de desempenho médio dos classificadores utilizando Xception para extrair as características. Classificação com redução de dimensão. Tempo de execução de cada classificador em segundos. **Tempo total de execução (treinamento e teste): 1 minuto e 19 segundos.**

Classificador	Acurácia(%)	Precisão(%)	Sensibilidade(%)	Medida-F(%)	Tempo (s)
MLP	89,0	87,0	85,7	86,4	17,0
Logistic Regression	88,5	85,9	84,7	85,3	32,7
Linear Discriminant Analysis	88,8	85,6	86,1	85,8	0,6
SVM	87,1	84,8	83,4	84,1	1,9
SGDC	87,7	86,3	83,2	84,7	0,4
K Neighbors Classifier	86,0	82,7	83,6	83,1	0,2
Bagging Classifier	80,2	77,9	74,7	76,2	14,1
Extra Trees Classifier	77,5	87,7	64,7	74,5	5,7
Decision Tree Classifier	74,0	71,3	70,4	70,9	2,1
Gaussian NB	76,3	78,9	67,1	72,5	0,3
Random Forest Classifier	55,2	-	35,4	-	3,6
Quadratic Discriminant Analysis	53,5	-	33,3	-	0,6

4.3 TRANSFERÊNCIA DE CONHECIMENTO (APENAS CORTE AXIAL) - ESTRATÉGIA 3

A Tabela 4.9 apresenta as métricas de desempenho utilizando DenseNet121 em diferentes cortes (axial, sagital e coronal). Observa-se que com o corte axial alcançou-se os melhores resultados de desempenho, logo neste trabalho, o ponto central foi em análises do corte axial. Nesta tabela, 80% dos dados foram separados para treinamento (20% das imagens de treinamento foram separadas para validação) e 20% para teste. O tamanho da imagem definido como 256x256 e 500 épocas.

Tabela 4.9: Métricas de desempenho da classificação de neoplasias cerebrais (glioma, meningioma e adenomas de hipófise) em MRI utilizando transferência de conhecimento (DenseNet121) em cada corte separadamente (axial, sagital, coronal).

Corte	Acurácia (%)	Precisão (%)	Sensibilidade (%)	F-score (%)
Axial	95,1	93,8	92,3	92,9
Sagital	91,9	91,6	92,2	91,8
Coronal	90,3	88,8	90,8	89,6

Além disso, a Tabela 4.10 apresenta as métricas de desempenho obtidas a partir de diferentes modelos de transferência de conhecimento utilizando apenas imagens do corte axial. Observa-se que DenseNet121 alcançou os melhores resultados de desempenho dentre todas as técnicas de transferência de conhecimento e, inclusive, todas as demais técnicas mencionadas nas seções anteriores deste trabalho. A seguir são apresentados os resultados detalhados, obtidos para

cada modelo utilizado com os dados de teste. Nesta tabela, 80% dos dados foram separados para treinamento (10% das imagens de treinamento foram separadas para validação) e 20% para teste. O tamanho da imagem definido como 224x224 e 150 épocas.

Tabela 4.10: Métricas de desempenho da classificação de neoplasias cerebrais (glioma, meningioma e adenomas de hipófise) em MRI utilizando transferência de conhecimento.

Classificador	Acurácia (%)	Precisão (%)	Sensibilidade (%)	F-score (%)
DenseNet121	96,8	96,8	94,8	95,6
MobileNet	95,7	95,8	93,2	94,2
EfficientNetV2 B0	91,9	91,5	89,7	90,5
Inception V3	90,8	91,9	85,6	87,4
Xception	90,8	90,8	86,2	88,0

Os gráficos na Figura 4.9 apresentam os resultados de treinamento e validação obtidos por transferência de conhecimento utilizando DenseNet121 e apenas o corte axial. Observa-se que apesar da oscilação inicial os valores de treinamento e validação estabilizam acima de 60 épocas, além da menor incidência de *overfitting*.




Figura 4.9: Resultados de treinamento e validação obtidos por transferência de conhecimento utilizando DenseNet121 e apenas o corte axial. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época.

Este modelo, que obteve os melhores resultados, também pode ser analisado e confirmado na matriz de confusão mostrada na Figura 4.10, pois, nessa matriz, as maiores porcentagens estão na diagonal principal, indicando que, sobretudo na classe glioma, os resultados foram

corretamente classificados durante o estágio de teste. Isto ocorreu, provavelmente, devido ao maior número de dados para treinamento e teste da classe MRI de pacientes com glioma.




Figura 4.10: Matriz de confusão obtida para o modelo DenseNet121, utilizando transferência de conhecimento, em porcentagem (%). Corte axial de três classes distintas, meningioma, glioma e adenomas de hipófise, respectivamente.

Além disso, verifica-se que 10,8% das imagens de meningioma foram confundidas com adenomas de hipófise. Isso pode ter ocorrido, visto que alguns tipos de meningiomas podem estar próximos a região de hipófise, confundindo, portanto, o classificador. Da mesma forma, as imagens que foram incorretamente classificadas como glioma, devido a diversidade de tipos de gliomas, podem ter confundido o classificador também.

As Figuras 4.11, 4.12, 4.13 e 4.14 apresentam o treinamento e a validação dos resultados obtidos por transferência de conhecimento utilizando MobileNet; EfficientNet B0; Inception V3; e Xception; respectivamente, todos analisando apenas o corte axial.

Portanto, transferência de conhecimento obteve os melhores resultados de desempenho entre todas as estratégias avaliadas nesta pesquisa, sobretudo utilizando Densenet 121. Entretanto, em transferência de conhecimento, é necessário maior quantidade de épocas para estabilização das curvas de treinamento e validação, em comparação com as estratégias de aumento de dados




Figura 4.11: Resultados de treinamento e validação obtidos por transferência de conhecimento utilizando MobileNet e apenas o corte axial. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época.




Figura 4.12: Resultados de treinamento e validação obtidos por transferência de conhecimento utilizando EfficientNetV2 B0 e apenas o corte axial. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época.

de CNN utilizada a partir de redes pré-treinadas, avaliando ambos com apenas imagens do corte axial.

É importante ressaltar também que, mesmo com a seleção de imagens apenas do corte axial, os modelos alcançaram desempenhos suficientemente expressivos em comparação com as demais análises, logo esse tipo de estratégia torna-se relevante para utilização em estudos deste




Figura 4.13: Resultados de treinamento e validação obtidos utilizando transferência de conhecimento com Inception V3 e apenas o corte axial. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época.

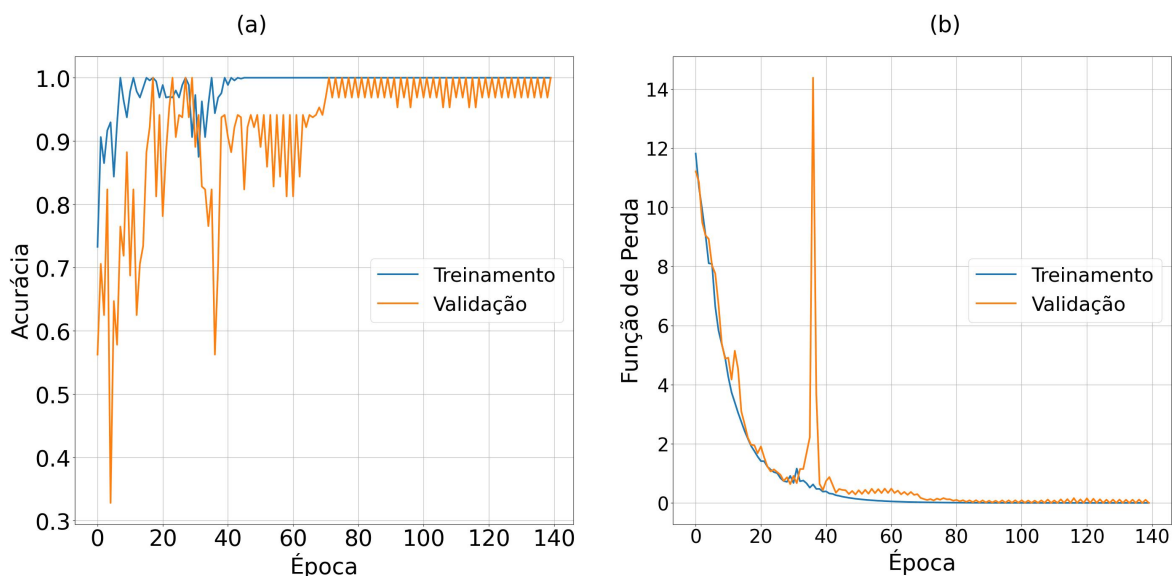


Figura 4.14: Resultados de treinamento e validação obtidos por transferência de conhecimento utilizando Xception e apenas o corte axial. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época.

contexto de classificação de neoplasias cerebrais. Esse resultado evidencia que é possível reduzir a quantidade de imagens de treinamento sem perda de desempenho.

Por fim, destaca-se que a estratégia de transferência de conhecimento não apenas superou as técnicas anteriores exploradas neste trabalho, mas também demonstrou eficácia diante do risco de *overfitting*. Logo, esses resultados de desempenho reforçam a relevância do uso de CNNs

em estratégias de transferência de conhecimento, como abordagem relevante para classificação automática de tumores cerebrais em MRI.

4.4 REDE ADVERSÁRIA GENERATIVA

Por fim, foram geradas imagens para treinamento das mesmas redes convolucionais anteriores, utilizando Rede Adversária Generativa (GAN), com o intuito de comparar os resultados obtidos. Após diversos treinamentos da GAN, obteve-se o resultado de perda em função de cada época (3000 no total), conforme mostrado no gráfico da Figura 4.15.




Figura 4.15: Gráfico do resultado obtido da geração de imagens utilizando Rede Adversária Generativa da perda em função da época.

Além disso, exemplos de imagens geradas de cada um tipo de classe são mostrados na Figura 4.16, com uma imagem da classe meningioma à esquerda, da classe glioma no meio e da classe adenoma de hipófise na imagem à direita.




Figura 4.16: Exemplos das três classes de MRI geradas por GAN de diferentes pacientes (à esquerda: Meningioma, meio: Glioma, direita: Adenomas de Hipófise).

Verificou-se que, mesmo com a presença de ruído, as imagens são geradas com a presença de tumor, conforme a classe dos dados reais de entrada. Apesar disso, a classe glioma gerou imagens as quais são mais difíceis de detectar presença do tumor, inclusive visualmente e isso pode ter dificultado a classificação das imagens.

A Tabela 4.11 apresenta os melhores resultados obtidos utilizando imagens geradas por Rede Adversária Generativa em estratégia de técnicas de aumento de dados com redes pré-treinadas, com apenas o corte axial, sem aumento de dados e com VGG16, conforme Estratégia 1 mencionada na Seção 4.1.

Tabela 4.11: Métricas de desempenho da classificação de neoplasias cerebrais (glioma, meningioma e adenomas de hipófise) em MRI utilizando imagens geradas por Rede Adversária Generativa em estratégia utilizando redes pré-treinadas (Seção 4.1).

Classificador	Acurácia (%)	Precisão (%)	Sensibilidade (%)	F-score (%)
VGG16	90,3	86,4	89,2	87,8

Relacionado a Tabela 4.11, o gráfico na Figura 4.17 apresenta os resultados de treinamento e validação obtidos pela CNN pré-treinada nas imagens geradas por Rede Adversária Generativa.

Verifica-se os resultados de medidas de desempenho com imagens geradas por GAN não alcançaram resultados superiores aos obtidos pela classificação das imagens reais (Tabela 4.10). Apesar disso, os resultados relevantes indicam que é possível utilizar esse tipo de geração de imagens para o desenvolvimento de sistema classificador de neoplasias cerebrais.




Figura 4.17: Resultados de treinamento (azul) e validação (laranja) obtidos pela CNN pré-treinada utilizando apenas o corte axial. Em ‘(a)’ está a acurácia em função da época, e em ‘(b)’ está a função de perda em função da época.

4.5 PESQUISAS CIENTÍFICAS ABORDADAS NO ESTADO DA ARTE

Algumas referências que utilizaram este banco de dados são (MONDAL; SHRIVASTAVA, 2022), (CHENG *et al.*, 2015), (CHENG *et al.*, 2016), (TALUKDER *et al.*, 2023), (ZULFIQAR *et al.*, 2023), (HAQ *et al.*, 2023) e (BISWAS; ISLAM, 2023).

A CNN foi utilizada em uma validação hold-out, alcançou uma acurácia de 99,6%, e com validação cruzada obteve uma acurácia de 98,4% (MONDAL; SHRIVASTAVA, 2022). Além disso, um estudo testou uma região de tumor aumentada como a Região de Interesse (ROI) e observou uma melhoria na precisão. Utilizando o histograma de intensidade, a precisão aumentou de 71,4% para 82,3%, a precisão do GLCM aumentou de 78,2% para 84,7%, e a precisão do modelo *Bag of Words (BoW)* aumentou de 83,5% para 88,2% (CHENG *et al.*, 2015).

Outro estudo, com a maioria dos mesmos autores mencionados em (CHENG *et al.*, 2015), envolveu pesquisadores da Escola de Engenharia Biomédica da *Southern Medical University em Guangzhou*, China. Este estudo alcançou uma precisão de 94,7% utilizando o mesmo banco de dados (CHENG *et al.*, 2016).

Em outra pesquisa que utilizou um modelo de aprendizado profundo para categorizar neoplasias cerebrais, uma acurácia de 99,7% foi alcançada ao empregar o ResNet50V2 com o banco

de dados utilizado para o desenvolvimento desta dissertação (TALUKDER *et al.*, 2023). Utilizando o EfficientNetB2, a acurácia atingiu 98,9% (ZULFIQAR *et al.*, 2023). Outro trabalho, empregando uma arquitetura de CNN, alcançou uma acurácia de 97,3% (HAQ *et al.*, 2023). Além disso, ao utilizar este banco de dados, outra investigação encontrou uma acurácia de 96,0% (BISWAS; ISLAM, 2023).

Em outra análise, as neoplasias cerebrais foram classificados usando uma CNN Profunda com transferência de conhecimento, empregando o GoogLeNet pré-treinado para extração de características. Esta pesquisa utilizou validação cruzada utilizando k-fold com k igual a cinco *folds*, resultando em uma acurácia média de classificação de 98% (DEEPAK; AMEER, 2019).

Da mesma forma, outro experimento focou na classificação de neoplasias cerebrais usando CNN. A acurácia de treinamento alcançada foi de 98,5%, com uma acurácia de validação de 84,2% (ABIWINANDA *et al.*, 2019).

Em outro projeto, a transferência de conhecimento foi empregada para a classificação de neoplasias cerebrais usando aprendizado profundo, alcançando uma acurácia de 98,7% (REHMAN *et al.*, 2019). Além disso, em uma aplicação semelhante de transferência de conhecimento, o estudo alcançou uma média de precisão de 96,1% em *k-fold* com k igual a 5 (SWATI *et al.*, 2019).

Em um estudo conduzido por outra equipe de pesquisa, o uso de CNN na mesma aplicação resultou em uma acurácia de 96,6% (BADŽA; BARJAKTAROVIĆ, 2020). Além disso, um estudo focado em uma abordagem de aprendizado profundo para a classificação e segmentação de neoplasias cerebrais usando uma CNN em múltiplas escalas alcançou uma acurácia de 97,3% (DÍAZ-PERNAS *et al.*, 2021).

Outro artigo discute um método híbrido de extração de características combinado com uma máquina de aprendizado extremo regularizada para a classificação de neoplasias cerebrais, alcançando uma acurácia que varia de 91,5% a 94,2% (GUMAEI *et al.*, 2019).

Algumas referências foram selecionadas como as principais fontes de pesquisa para obter uma tabela (Tabela 4.12) e comparar as metodologias e resultados de cada estudo, resumindo as informações de cada publicação. Além das referências sobre detecção de neoplasias cerebrais usando aprendizado de máquina que utilizaram o mesmo conjunto de dados deste trabalho, há

inúmeros outros estudos de pesquisa sobre este tema com conjuntos de dados diferentes.

Um artigo discute o aprendizado *ensemble* para classificação cerebral usando ressonância magnética (VAIYAPURI *et al.*, 2023). Outra abordagem sobre detecção de neoplasias cerebrais utiliza a Rede Generativa Adversarial (GAN) para aprimorar a resolução de imagem. Neste estudo, a acurácia, medida F, precisão, sensibilidade e a área sob a curva ROC atingiram aproximadamente 100% em casos específicos (MOHSEN *et al.*, 2023). Além disso, em relação as GANs, alguns outros recentes estudos apresentam o uso dessa estratégia para melhorar a classificação de imagens de neoplasias cerebrais (KARPAKAM; KUMARESHAN, 2025; ALMUHAIMED *et al.*, 2025; VURE; PAPPALA, 2025; AFIF *et al.*, 2025).

4.6 DISCUSSÕES GERAIS DOS RESULTADOS

Os resultados de alguns modelos produziram valores abaixo do esperado, além de ter ocorrido *overfitting* e *underfitting*, utilizando, por exemplo, técnicas tradicionais de aumento de dados. Por outro lado, o uso de transferência de conhecimento com imagens reais proporcionou melhores resultados de desempenho, além do uso de estratégias de aumento de dados presentes no estado da arte. Os resultados obtidos utilizando CNN foram próximos dos resultados alcançados por algumas pesquisas na literatura as quais consideram todos os cortes simultaneamente. Logo, as estratégias empregadas em cenários com quantidades restritas de dados, avaliando apenas imagens do corte axial, sobretudo a CNN, utilizando transferência de conhecimento, foram eficazes.

Entretanto, algumas imagens foram classificadas de maneira incorreta, provavelmente, porque alguns tipos de meningiomas podem estar próximos a região de hipófise, confundindo o classificador. Além disso, imagens que possuem glioma, devido sua diversidade de tipos, podem também ter comprometido o treinamento.

Apesar disso, dentre as estratégias avaliadas, a técnica de transferência de conhecimento mostrou-se a mais eficiente, destacando-se sobretudo as métricas de desempenho obtidas. Isto está de acordo com o que foi apresentado pela literatura (REHMAN *et al.*, 2019; SWATI *et al.*, 2019). A utilização de modelos de transferência de conhecimento, especialmente DenseNet121, garantiu desempenho superior em todas as métricas avaliadas. Estes resultados atingiram

valores médios de acurácia de até 96,8%, com precisão atingindo 96,8%, recall de 94,8% e F-measure de 95,6%, utilizando modelo DenseNet121, evidenciando que essa abordagem é capaz de extrair características relevantes, mesmo em um cenário restrito ao corte axial, ou seja, além do que é apresentado pela literatura.

Portanto, este trabalho não apenas confirma a efetividade do uso de arquiteturas avançadas de aprendizagem profundo para o diagnóstico por imagem, como também amplia o escopo da literatura ao demonstrar que a aplicação de transferência de conhecimento em dados axiais isolados pode superar ou, no mínimo, igualar resultados obtidos por metodologias que consideram múltiplas sequências e cortes de ressonância magnética (MONDAL; SHRIVASTAVA, 2022), (CHENG *et al.*, 2015), (CHENG *et al.*, 2016), (TALUKDER *et al.*, 2023), (ZULFIQAR *et al.*, 2023), (HAQ *et al.*, 2023) e (BISWAS; ISLAM, 2023).

Dessa forma, os experimentos conduzidos contribuem para aprofundar o conhecimento, o estudo, o treinamento e a validação de técnicas aplicadas ao reconhecimento de neoplasias cerebrais, consolidando o transferência de conhecimento como a estratégia mais promissora, neste contexto, corroborando com o que é apresentado na literatura (DEEPAK; AMEER, 2019; REHMAN *et al.*, 2019; SWATI *et al.*, 2019).

Além da utilização de imagens geradas por estratégias de aumento de dados durante a fase de treinamento destas redes, conforme também apresentado no estado da arte (MOHSEN *et al.*, 2023; KARPAKAM; KUMARESHAN, 2025; ALMUHAIMEED *et al.*, 2025; VURE; PAPPALA, 2025; AFIF *et al.*, 2025), este estudo avaliou sistematicamente o impacto dessas estratégias no desempenho da classificação. Esses resultados com geração de imagens, utilizando Rede Adversária Generativa, não foram superiores aos maiores resultados de transferência de conhecimento, mas são relevantes, com acurácia média de até 90,3%, precisão de até 86,4%, sensibilidade de até 89,2% e medida-F de até 87,8%, utilizando redes pré-treinadas e modelo VGG16.

Observou-se que os resultados obtidos por este trabalho e apresentados nas seções anteriores são próximos, e em alguns casos superiores, aos reportados na literatura. Entretanto, não foi identificado nenhum estudo que explorasse especificamente a classificação de neoplasias cerebrais utilizando exclusivamente imagens do corte axial, sob as mesmas condições, parâmetros e estratégias aqui propostas. Essa escolha metodológica demonstra que, mesmo restringindo a

análise a um único plano de aquisição, foi possível alcançar métricas robustas e comparáveis a abordagens mais complexas. Além disso, durante as análises realizadas neste trabalho, houve o cuidado de evitar o vazamento de dados, aspecto que não foi explicitamente mencionado nos artigos científicos encontrados na literatura.

O fato dessas estratégias, apesar de terem sido aplicadas em quantidades restritas de dados, terem resultados de desempenho relevantes indica que é possível melhorar a eficiência dos classificadores, além de reduzir o custo computacional, devido a redução do tempo de treinamento. Tal cenário facilita a reprodutibilidade dos experimentos, além de otimizar a utilização dessas abordagens em análises de bancos de dados, de outras aplicações, com quantidades restrita de imagens.

Tabela 4.12: Pesquisas utilizando o conjunto de dados (CHENG, 2017) para a classificação por ressonância magnética de três doenças (meningioma, glioma e adenomas de hipófise) - apresentando a melhor acurácia média (%) e o tipo de modelos utilizados.

Referência	Modelo	Ac. (%)
(MONDAL; SHRIVASTAVA, 2022)	CNN (BMRI-Net) - Hold-out	99,6
(NOREEN <i>et al.</i> , 2020)	DensNet201	99,5
(NOREEN <i>et al.</i> , 2020)	Inception-v3	99,3
(SAHOO <i>et al.</i> , 2023)	progressive growing GAN (PGGAN)	98,8
(DEEPAK; AMEER, 2019)	Pre-trained GoogLeNet to extract features, Five-fold cross-validation	98,0
(CHENG <i>et al.</i> , 2016)	augment the tumor region, adaptive spatial division method, Fisher kernel framework	94,7
(GUMAEI <i>et al.</i> , 2019)	PCA-NGIST and Regularized extreme learning machine (RELM), random holdout	94,2
(CHENG <i>et al.</i> , 2015)	ring-form partition- BoW model	91,3
(ANAGUN, 2023)	2D Convolutional Neural Network (CNN)	91,3

CONCLUSÃO

Este estudo consistiu em investigação sistemática do desenvolvimento de um sistema de auxílio ao diagnóstico médico, utilizando modelos de classificação e aumento de dados. Esta abordagem foi baseada em diferentes classificadores de MRI do cérebro, aplicando algoritmos para auxiliar no diagnóstico de neoplasias cerebrais, especificamente para identificar três tipos diferentes, tais como, meningioma, glioma e adenomas de hipófise.

Diante dos resultados relevantes dos modelos, é importante mencionar as implicações clínicas dos resultados obtidos. A aplicabilidade dessas técnicas pode representar um avanço significativo no suporte ao diagnóstico de neoplasias cerebrais, contribuindo para decisões clínicas mais rápidas, precisas e, também, podendo ser obtidas por meio de um achado incidental. Em síntese, observou-se, neste trabalho, que é possível selecionar arquiteturas mais simples possíveis e que possam ser treinadas com bases menores, analisando apenas um corte (no caso, o corte axial), utilizando estratégias de aumento de dados.

Portanto, após as avaliações sistemáticas realizadas, verifica-se que as estratégias utilizadas neste estudo podem, inclusive, contribuir para avanços científicos relacionados a outras aplicações de AI em MRI de cérebro, além deste caso, que consistiu em análises de neoplasias cerebrais. Além das abordagens e aplicações apresentadas na literatura que possuam quantidades restritas de dados. Tal situação também contribui para a redução do custo computacional, otimizando a utilização dessas abordagens.

Diante disso, uma proposta de trabalho futuro seria a investigação da geração de imagens e de classificações com intuito de alcançar resultados de desempenho superiores aos resultados obtidos, inclusive em outras aplicações. Além disso, outro possível trabalho futuro, seria a avaliação da complexidade das soluções, processamento e consumo de energia, que pode ser útil, por exemplo, em sistemas embarcados.

REFERÊNCIAS

- ABIWINANDA, N.; HANIF, M.; HESAPUTRA, S. T.; HANDAYANI, A.; MENGKO, T. R. Brain Tumor Classification Using Convolutional Neural Network. Springer Singapore, p. 183–189, 2019. Disponível em: <http://dx.doi.org/10.1007/978-981-10-9035-6_33>. Citado na página 60.
- AFIF, M. M.; NOMAN, A. A.; KABIR, K. M. T.; AHMMED, M. M.; RAHMAN, M. M.; MAHMUD, M.; BABU, M. A. *Proportional Sensitivity in Generative Adversarial Network (GAN)-Augmented Brain Tumor Classification Using Convolutional Neural Network*. 2025. Disponível em: <<https://arxiv.org/abs/2506.17165>>. Citado 2 vezes nas páginas 61 e 62.
- AGGARWAL, C. *Neural Networks and Deep Learning: A Textbook*. Springer International Publishing, 2018. ISBN 9783319944647. Disponível em: <<https://books.google.com.br/books?id=AsTswQEACAAJ>>. Citado na página 22.
- AHMAD, B.; SUN, J.; YOU, Q.; PALADE, V.; MAO, Z. Brain tumor classification using a combination of variational autoencoders and generative adversarial networks. *Biomedicines*, MDPI, v. 10, n. 2, p. 1–19, 2022. Citado na página 26.
- AIZENBERG, I.; AIZENBERG, N. N.; VANDEWALLE, J. P. *Multi-Valued and Universal Binary Neurons: Theory, Learning and Applications*. [S.l.]: Springer Science & Business Media, 2000. Citado na página 22.
- AKINYELU, A. A.; ZACCAGNA, F.; GRIST, J. T.; CASTELLI, M.; RUNDO, L. Brain Tumor Diagnosis Using Machine Learning, Convolutional Neural Networks, Capsule Neural Networks and Vision Transformers, Applied to MRI: A Survey. *Journal of Imaging*, v. 8, n. 8, p. 205, Julho 2022. ISSN 2313-433X. Disponível em: <<https://www.mdpi.com/2313-433X/8/8/205>>. Citado na página 6.
- ALBALAWI, E.; T.R, M.; THAKUR, A.; KUMAR, V. V.; GUPTA, M.; KHAN, S. B.; ALMUSHARRAF, A. Integrated approach of federated learning with transfer learning for classification and diagnosis of brain tumor. *BMC Medical Imaging*, v. 24, n. 1, p. 1–15, 2024. ISSN 14712342. Citado na página 2.
- ALMUHAIMEED, A.; BILAL, A.; ALZHRANI, A.; ALRASHIDI, M.; ALGHAMDI, M.; SARWAR, R. Brain tumor classification using GAN-augmented data with autoencoders and Swin Transformers. *Frontiers in Medicine*, v. 12, n. August, p. 1–26, aug 2025. ISSN 2296-858X. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fmed.2025.1635796/full>>. Citado 2 vezes nas páginas 61 e 62.
- ALPAYDIN, E. *Introduction to Machine Learning*. 3. ed. Cambridge, MA: MIT Press, 2014. (Adaptive Computation and Machine Learning). ISBN 978-0-262-02818-9. Citado 3 vezes nas páginas 19, 20 e 21.

- ALRASHEDY, H. H. N.; ALMANSOUR, A. F.; IBRAHIM, D. M.; HAMMOUDEH, M. A. A. BrainGAN: Brain MRI Image Generation and Classification Framework Using GAN Architectures and CNN Models. *Sensors (Basel, Switzerland)*, MDPI, v. 22, n. 11, p. 4297, 2022. Citado na página 26.
- ALRUMIAH, S. S.; ALREBDI, N.; IBRAHIM, D. M. Augmenting healthy brain magnetic resonance images using generative adversarial networks. *PeerJ Computer Science*, v. 9, p. e1318, 2023. Disponível em: <<https://doi.org/10.7717/peerj-cs.1318>>. Citado na página 27.
- AMIN, J.; SHARIF, M.; HALDORAI, A.; YASMIN, M.; NAYAK, R. S. Brain tumor detection and classification using machine learning: a comprehensive survey. *Complex Intelligent Systems*, Springer International Publishing, v. 8, n. 4, p. 3161–3183, Agosto 2022. ISSN 2199-4536. Disponível em: <<https://doi.org/10.1007/s40747-021-00563-yhttps://link.springer.com/10.1007/s40747-021-00563-y>>. Citado na página 3.
- ANAGUN, Y. Smart brain tumor diagnosis system utilizing deep convolutional neural networks. *Multimedia Tools and Applications*, Springer US, n. 0123456789, 2023. ISSN 15737721. Disponível em: <<https://doi.org/10.1007/s11042-023-15422-w>>. Citado 2 vezes nas páginas 2 e 64.
- ANITA, J. N.; KUMARAN, S. A Deep Learning Architecture for Meningioma Brain Tumor Detection and Segmentation. *Journal of Cancer Prevention*, v. 27, n. 3, p. 192–198, 2022. ISSN 2288-3649. Citado na página 2.
- ARIF, M.; AJESH, F.; SHAMSUDHEEN, S.; GEMAN, O.; IZDRUI, D.; VICOVEANU, D. Brain Tumor Detection and Classification by MRI Using Biologically Inspired Orthogonal Wavelet Transform and Deep Learning Techniques. *Journal of Healthcare Engineering*, v. 2022, p. 1–18, Janeiro 2022. ISSN 2040-2309. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/35047149http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC8763556https://www.hindawi.com/journals/jhe/2022/2693621/>>. Citado na página 3.
- ARUMUGAM, M.; THIYAGARAJAN, A.; ADHI, L.; ALAGAR, S. Crossover smell agent optimized multilayer perceptron for precise brain tumor classification on mri images. *Expert Systems with Applications*, Elsevier, v. 238, p. 121453, 2024. Citado na página 2.
- BADŽA, M. M.; BARJAKTAROVIĆ, M. C. Classification of brain tumors from mri images using a convolutional neural network. *Applied Sciences (Switzerland)*, v. 10, n. 6, 2020. ISSN 20763417. Citado na página 60.
- BISWAS, A.; ISLAM, M. S. A Hybrid Deep CNN-SVM Approach for Brain Tumor Classification. *Journal of Information Systems Engineering and Business Intelligence*, v. 9, n. 1, p. 1–15, Abril 2023. ISSN 2443-2555. Disponível em: <<https://e-journal.unair.ac.id/JISEBI/article/view/38587>>. Citado 3 vezes nas páginas 59, 60 e 62.
- CASTILLO, M. History and evolution of brain tumor imaging: insights through radiology. *Radiology*, v. 273, n. 2 Suppl, p. S111–25, Novembro 2014. ISSN 1527-1315. Disponível em: <<http://pubs.rsna.org/doi/10.1148/radiol.14140130http://www.ncbi.nlm.nih.gov/pubmed/25340432>>. Citado na página 8.
- CHENG, J. *brain tumor dataset*. 2017. Acessado em 30 de Agosto de 2023. Disponível em: <https://figshare.com/articles/dataset/brain_tumor_dataset/1512427>. Citado 8 vezes nas páginas vii, ix, 4, 16, 18, 28, 29 e 64.

- CHENG, J.; HUANG, W.; CAO, S.; YANG, R.; YANG, W.; YUN, Z.; WANG, Z.; FENG, Q. Enhanced Performance of Brain Tumor Classification via Tumor Region Augmentation and Partition. *PloS one*, v. 10, n. 10, Outubro 2015. ISSN 1932-6203. Disponível em: <<https://dx.plos.org/10.1371/journal.pone.0140381><http://www.ncbi.nlm.nih.gov/pubmed/26447861><http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC4598126>>. Citado 6 vezes nas páginas vii, 28, 29, 59, 62 e 64.
- CHENG, J.; YANG, W.; HUANG, M.; HUANG, W.; JIANG, J.; ZHOU, Y.; YANG, R.; ZHAO, J.; FENG, Y.; FENG, Q.; CHEN, W. Retrieval of Brain Tumors by Adaptive Spatial Pooling and Fisher Vector Representation. *PloS one*, v. 11, n. 6, p. e0157112, Junho 2016. ISSN 1932-6203. Disponível em: <<https://dx.plos.org/10.1371/journal.pone.0157112><http://www.ncbi.nlm.nih.gov/pubmed/27273091><http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC4894628>>. Citado 4 vezes nas páginas 28, 59, 62 e 64.
- CHITTATHURU, D.; UN, N.; REDDY, P.; GADEKALLU, T.; IWENDI, C.; WEI, C.; XIN, Q. Identification of malnutrition and prediction of bmi from facial images using real-time image processing and machine learning. *IET Image Processing*, v. 16, 05 2021. Citado na página 26.
- DAI, X.; XU, Y.; SONG, H.; ZHENG, J. Using image-based machine learning and numerical simulation to predict pesticide inline mixing uniformity. *Journal of the Science of Food and Agriculture*, v. 103, n. 2, p. 705–719, 2023. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1002/jsfa.12182>>. Citado na página 25.
- DEANGELIS, L. M. Brain Tumors. *Medical Progress N Engl J Med*, v. 114, n. 2, p. 114–123, 2001. Citado 4 vezes nas páginas 14, 15, 16 e 17.
- DECHTER, R. *Learning while searching in constraint-satisfaction problems*. Tese (Doutorado) — University of California, Computer Science Department, Cognitive Systems Laboratory, 1986. Online. Citado na página 22.
- DEEPAK, S.; AMEER, P. M. Brain tumor classification using deep CNN features via transfer learning. *Computers in Biology and Medicine*, Elsevier Ltd, v. 111, p. 103345, Junho 2019. ISSN 0010-4825. Disponível em: <<https://doi.org/10.1016/j.combiomed.2019.103345>>. Citado 3 vezes nas páginas 60, 62 e 64.
- DEEPAK, S.; AMEER, P. M. MSG-GAN Based Synthesis of Brain MRI with Meningioma for Data Augmentation. In: *2020 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT)*. [s.n.], 2020. p. 1–6. Disponível em: <<https://doi.org/10.1109/CONECCT50063.2020.9198672>>. Citado na página 27.
- DICOM Standard. *History of DICOM*. 2023. <<https://www.dicomstandard.org/history>>. Acesso em: 10 set. 2025. Citado na página 19.
- DOMINGOS, P. A few useful things to know about machine learning. *Communications of the ACM*, v. 55, n. 10, p. 78–87, Outubro 2012. ISSN 0001-0782. Disponível em: <<https://dl.acm.org/doi/10.1145/2347736.2347755>>. Citado 2 vezes nas páginas 19 e 20.
- DORFNER, F. J.; PATEL, J. B.; KALPATHY-CRAMER, J.; GERSTNER, E. R.; BRIDGE, C. P. *A review of deep learning for brain tumor analysis in MRI*. [S.l.]: Nature Research, 2025. Citado na página 2.

- DÍAZ-PERNAS, F. J.; MARTÍNEZ-ZARZUELA, M.; ANTÓN-RODRÍGUEZ, M.; GONZÁLEZ-ORTEGA, D. A Deep Learning Approach for Brain Tumor Classification and Segmentation Using a Multiscale Convolutional Neural Network. *Healthcare*, 2021. Citado na página 60.
- E., T.; SARULADHA, K. Design of FCSE-GAN for Dissection of Brain Tumour in MRI. In: *2020 International Conference on Smart Technologies in Computing, Electrical and Electronics (ICSTCEE)*. [S.l.]: IEEE, 2020. p. 1–6. Citado na página 27.
- FARIA, E. G. C. d.; NASCIMENTO, F. A. O.; MIOSSO, C. J. *Sistema Inteligente para Classificação Automática de Imagens de Ressonância Magnética de Neoplasias Cerebrais utilizando Redes Neurais Convolucionais*. 2025. Patente de Programa de Computador. Registro BR512025005453-0, 28 out. 2025. Instituto Nacional da Propriedade Industrial (INPI). Citado na página 29.
- GE, C.; GU, I. Y. H.; JAKOLA, A. S.; YANG, J. Enlarged Training Dataset by Pairwise GANs for Molecular-Based Brain Tumor Classification. *IEEE Access*, v. 8, p. 22560–22570, 2020. Disponível em: <<https://doi.org/10.1109/ACCESS.2020.2969805>>. Citado 2 vezes nas páginas 26 e 27.
- GEROVITCH, S. How the computer got its revenge on the soviet union. *Nautilus*, Abril 2015. Archived from the original on 22 September 2021. Retrieved 19 September 2021. Disponível em: <<https://nautil.us/issue/24/error/how-the-computer-got-its-revenge-on-the-soviet-union>>. Citado na página 21.
- GOODFELLOW, I. J.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016. <<http://www.deeplearningbook.org>>. Citado na página 22.
- GUMAEI, A.; HASSAN, M. M.; HASSAN, M. R.; ALELAIWI, A.; FORTINO, G. A Hybrid Feature Extraction Method With Regularized Extreme Learning Machine for Brain Tumor Classification. *IEEE Access*, IEEE, v. 7, n. c, p. 36266–36273, 2019. ISSN 2169-3536. Disponível em: <<https://ieeexplore.ieee.org/document/8664160/>>. Citado 2 vezes nas páginas 60 e 64.
- HAMGHALAM, M.; SIMPSON, A. L. Medical image synthesis via conditional GANs: Application to segmenting brain tumours. *Computers in Biology and Medicine*, Elsevier, v. 170, p. 107982, Junho 2024. Citado na página 27.
- HAN, C.; RUNDO, L.; ARAKI, R.; NAGANO, Y.; FURUKAWA, Y.; MAURI, G.; NAKAYAMA, H.; HAYASHI, H. Combining noise-to-image and image-to-image GANs: Brain MR image augmentation for tumor detection. *IEEE Access*, v. 7, p. 156966–156977, 2019. Disponível em: <<https://doi.org/10.1109/ACCESS.2019.2947606>>. Citado na página 26.
- HAQ, E. U.; JIANJUN, H.; LI, K.; HAQ, H. U.; ZHANG, T. An MRI-based deep learning approach for efficient classification of brain tumors. *Journal of Ambient Intelligence and Humanized Computing*, Springer Berlin Heidelberg, v. 14, n. 6, p. 6697–6718, Junho 2023. ISSN 1868-5137. Disponível em: <<https://doi.org/10.1007/s12652-021-03535-9>><https://link.springer.com/10.1007/s12652-021-03535-9>>. Citado 3 vezes nas páginas 59, 60 e 62.
- HASAN, K.; HOSSAIN, R. B.; HASAN, M. Convolutional Neural Networks for Automated Classification of Brain Tumors. *North American Academic Research*, Setembro 2023. Citado na página 2.

- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2nd. ed. [S.l.]: Springer Science & Business Media, 2009. Citado na página 21.
- HOLMES, O. W. History of Brain Tumor Surgery – A Global and Indian Perspective. *Archives of Medicine and Health Sciences*, 2021. Citado 4 vezes nas páginas 8, 9, 10 e 12.
- HOSCH, W. L. machine learning - artificial intelligence. *Encyclopedia Britannica*, Dezembro 2022. Accessed 8 February 2023. Disponível em: <<https://www.britannica.com/technology/machine-learning>>. Citado na página 19.
- HOSSAIN, R.; IBRAHIM, R. B.; HASHIM, H. B. Automated Brain Tumor Detection Using Machine Learning: A Bibliometric Review. *World Neurosurgery*, Elsevier Inc., v. 175, p. 57–68, 2023. ISSN 18788769. Disponível em: <<https://doi.org/10.1016/j.wneu.2023.03.115>>. Citado na página 25.
- HOSSAIN, S.; CHAKRABARTY, A.; GADEKALLU, T. R.; ALAZAB, M.; PIRAN, M. J. Vision Transformers, Ensemble Model, and Transfer Learning Leveraging Explainable AI for Brain Tumor Detection and Classification. *IEEE Journal of Biomedical and Health Informatics*, IEEE, v. 28, n. 3, p. 1261–1272, 2024. ISSN 21682208. Citado na página 2.
- INCA. *Câncer do sistema nervoso central*. [S.l.], 2022. INCA - Instituto Nacional do Câncer. Câncer do sistema nervoso central. Disponível em: <<https://www.gov.br/inca/pt-br/assuntos/cancer/tipos/sistema-nervoso-central>>. Citado 4 vezes nas páginas 1, 8, 13 e 14.
- International Agency for Research on Cancer. *Global Cancer Observatory*. 2023. <<https://gco.iarc.fr/today/home>>. Acesso em 9 de março de 2023. Citado na página 13.
- JR, E. R. L.; KAYE, A. H. *Brain Tumors: An Encyclopedic Approach*. [S.l.]: Churchill Livingstone, 2002. Citado 3 vezes nas páginas 9, 10 e 11.
- KARPAKAM, S.; KUMARESHAN, N. Enhanced brain tumor detection and classification using a deep image recognition generative adversarial network (DIR-GAN): a comparative study on MRI, X-ray, and FigShare datasets. *Neural Computing and Applications*, Springer London, v. 37, n. 14, p. 8731–8758, may 2025. ISSN 0941-0643. Disponível em: <<https://doi.org/10.1007/s00521-025-11031-w>>. Citado 2 vezes nas páginas 61 e 62.
- KERR, P. B.; CAPUTY, A. J.; HORWITZ, N. H. A history of cerebral localization. *Neurosurgical focus*, v. 18, n. 4, p. e1, Abril 2005. ISSN 1092-0684. Disponível em: <<https://thejns.org/view/journals/neurosurg-focus/18/4/foc.2005.18.4.2.xml>>. Citado 2 vezes nas páginas 10 e 11.
- KHAN, M. A. An automated and fast system to identify covid-19 from x-ray radiograph of the chest using image processing and machine learning. *International Journal of Imaging Systems and Technology*, Wiley Online Library, v. 31, n. 2, p. 499–508, 2021. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1002/ima.22564>>. Citado na página 25.
- KHAN, M. S. I.; RAHMAN, A.; DEBNATH, T.; KARIM, M. R.; NASIR, M. K.; BAND, S. S.; MOSAVI, A.; DEHZANGI, I. Accurate brain tumor detection using deep convolutional neural network. *Computational and Structural Biotechnology Journal*, The Author(s), v. 20, p. 4733–4745, 2022. ISSN 20010370. Disponível em: <<https://doi.org/10.1016/j.csbj.2022.08.039>>.

[//linkinghub.elsevier.com/retrieve/pii/S2001037022003737](https://linkinghub.elsevier.com/retrieve/pii/S2001037022003737)>. Citado 2 vezes nas páginas 3 e 26.

KOMORI, T. Updated 2016 WHO classification of tumors of the CNS: Turning the corner where molecule meets pathology. *Brain Tumor Pathology*, v. 34, p. 139–140, 2017. Citado na página 11.

KUMAR, T. Early Diagnosis of Brain Tumor Using AI and Mathematical Modeling. *INTERANTIONAL JOURNAL OF SCIENTIFIC RESEARCH IN ENGINEERING AND MANAGEMENT*, v. 09, p. 1–9, Janeiro 2025. ISSN 25823930. Disponível em: <<https://ijsrem.com/download/early-diagnosis-of-brain-tumor-using-ai-and-mathematical-modeling/>>. Citado na página 2.

LAKSHMI, K.; AMARAN, S.; SUBBULAKSHMI, G.; PADMINI, S.; JOSHI, G. P.; CHO, W. Explainable artificial intelligence with UNet based segmentation and Bayesian machine learning for classification of brain tumors using MRI images. *Scientific Reports, Nature Research*, v. 15, Janeiro 2025. ISSN 20452322. Citado na página 2.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, Maio 2015. ISSN 0028-0836. Disponível em: <<https://www.nature.com/articles/nature14539>>. Citado na página 22.

LEITE, C. d. C.; JUNIOR, E. A.; LUCATO, L. T. *Neurorradiologia: diagnóstico por imagem das alterações encefálicas*. [S.l.]: Guanabara Koogan, 2008. Citado 2 vezes nas páginas 17 e 18.

LINDSAY, R. P. The impact of automation on public administration. *Western Political Quarterly*, v. 17, n. 3, p. 78–81, 1964. ISSN 0043-4078. Archived from the original on 6 October 2021. Retrieved 6 October 2021. Citado na página 21.

LOUIS, D. N.; OHGAKI, H.; WIESTLER, O. D.; CAVENEE, W. K.; BURGER, P. C.; JOUVET, A.; SCHEITHAUER, B. W.; KLEIHUES, P. The 2007 WHO Classification of Tumours of the Central Nervous System. *Acta Neuropathologica*, v. 114, p. 97–109, 2007. ISSN 1432-0533. Citado na página 12.

LUGER, G. F. *Inteligência Artificial: Estruturas e Estratégias para a Solução de Problemas Complexos*. 4th. ed. Porto Alegre: Bookman, 2004. 774 p. ISBN 85-363-0396-4. Citado na página 20.

LUO, J.; PAN, M.; MO, K.; MAO, Y.; ZOU, D. Emerging role of artificial intelligence in diagnosis, classification and clinical management of glioma. *Seminars in Cancer Biology*, v. 91, p. 110–123, Junho 2023. ISSN 1044579X. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/36907387https://linkinghub.elsevier.com/retrieve/pii/S1044579X23000457>>. Citado na página 25.

MA, Y. Federated Learning for Brain Tumor Diagnosis: Methods, Challenges and Future Prospects. *ITM Web of Conferences*, v. 70, p. 03028, Janeiro 2025. ISSN 2271-2097. Disponível em: <<https://www.itm-conferences.org/10.1051/itmconf/20257003028>>. Citado na página 2.

MACEWEN, W. Intra-cranial lesions. In: WILKINS, R. H. (Ed.). *Neurosurgical Classics*. New York: Johnson Reprint Corp., 1965. p. 374–375. Citado na página 10.

- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, v. 5, p. 115–137, 1943. Citado na página 20.
- MOHSEN, S.; ALI, A. M.; EL-RABAIE, E. S. M.; ELKASEER, A.; SCHOLZ, S. G.; HASSAN, A. M. A. Brain Tumor Classification Using Hybrid Single Image Super-Resolution Technique With ResNext101_32× 8d and VGG19 Pre-Trained Models. *IEEE Access*, IEEE, v. 11, p. 55582–55595, Maio 2023. ISSN 21693536. Citado 3 vezes nas páginas 27, 61 e 62.
- MONDAL, A.; SHRIVASTAVA, V. K. A novel Parametric Flatten-p Mish activation function based deep CNN model for brain tumor classification. *Computers in Biology and Medicine*, Elsevier Ltd, v. 150, p. 106183, Novembro 2022. ISSN 18790534. Disponível em: <<https://doi.org/10.1016/j.compbimed.2022.106183>>. Citado 3 vezes nas páginas 59, 62 e 64.
- MUGDHA, S. B. S.; UDDIN, M. Neurosight: A deep-learning integrated efficient approach to brain tumor detection. *Engineering Reports*, John Wiley and Sons Inc, v. 7, Janeiro 2025. ISSN 25778196. Citado na página 2.
- NAG, A.; MONDAL, H.; HASSAN, M. M.; AL-SHEHARI, T.; KADRIE, M.; AL-RAZGAN, M.; ALFAKIH, T.; BISWAS, S.; BAIRAGI, A. K. TumorGANet: A Transfer Learning and Generative Adversarial Network-based Data Augmentation Model for Brain Tumor Classification. *IEEE Access*, IEEE, v. 12, p. 103060–103081, Maio 2024. ISSN 21693536. Citado na página 2.
- NAYAK, D. R.; PADHY, N.; MALLICK, P. K.; SINGH, A. A deep autoencoder approach for detection of brain tumor images. *Computers and Electrical Engineering*, Elsevier Ltd, v. 102, p. 108238, 2022. ISSN 00457906. Disponível em: <<https://doi.org/10.1016/j.compeleceng.2022.108238><https://linkinghub.elsevier.com/retrieve/pii/S0045790622004748>>. Citado 2 vezes nas páginas 3 e 26.
- NEMA. *Digital Imaging and Communications in Medicine (DICOM)*. 2023. <https://dicom.nema.org/medical/dicom/current/output/chtml/part01/sect_1.3.html>. Acesso em: 10 set. 2025. Citado 2 vezes nas páginas 18 e 19.
- NIA, N. G.; KAPLANOGLU, E.; NASAB, A. Evaluation of artificial intelligence techniques in disease diagnosis and prediction. *Discover Artificial Intelligence*, Springer International Publishing, v. 3, n. 1, p. 5, Janeiro 2023. ISSN 2731-0809. Disponível em: <<https://doi.org/10.1007/s44163-023-00049-5><https://link.springer.com/10.1007/s44163-023-00049-5>>. Citado 2 vezes nas páginas 22 e 25.
- NIH. *What is Cancer?* [S.l.], 2021. Disponível em: <<https://www.cancer.gov/about-cancer/understanding/what-is-cancer>>. Citado na página 13.
- NOREEN, N.; PALANIAPPAN, S.; QAYYUM, A.; AHMAD, I.; IMRAN, M.; SHOAIIB, M. A Deep Learning Model Based on Concatenation Approach for the Diagnosis of Brain Tumor. *IEEE Access*, IEEE, v. 8, p. 55135–55144, 2020. ISSN 21693536. Citado na página 64.
- OPENCV-TEAM. *OpenCV-Python: Open Source Computer Vision Library*. 2024. <<https://pypi.org/project/opencv-python/>>. Acesso em: Julho de 2025. Citado na página 30.
- OSBORN, A. G. *Encéfalo de Osborn: imagem, patologia e anatomia*. Porto Alegre: Artmed, 2014. Revisão técnica: Leonardo Modesti Vedolin. Citado 2 vezes nas páginas 16 e 18.

- PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011. Citado 2 vezes nas páginas vii e 35.
- PIZER, S. M.; ACKERMAN, L. V. Dicom: Digital imaging and communications in medicine. *Radiographics*, v. 16, n. 2, p. 345–346, 1996. Citado na página 19.
- PP, K.; KP, P. The Ancient Greek Discovery of the Nervous System: Alcmaeon, Praxagoras and Herophilus. *Journal of Neurology and Neuroscience*, v. 06, n. s1, p. 1–5, 2015. ISSN 21716625. Disponível em: <<http://www.jneuro.com/neurology-neuroscience/the-ancient-greek-discovery-of-the-nervous-systemalcmaeon-praxagoras-and-herophilus.php?aid=6917>>. Citado 2 vezes nas páginas 8 e 9.
- PREUL, M. C. History of brain tumor surgery. *Neurosurg Focus*, v. 18, n. 4, 2005. Citado 2 vezes nas páginas 10 e 12.
- REHMAN, A.; NAZ, S.; IMRAN, M.; AKRAM, F.; IMRAN, M. A Deep Learning-Based Framework for Automatic Brain Tumors Classification Using Transfer Learning. *Circuits, Systems, and Signal Processing*, Springer US, 2019. ISSN 1531-5878. Disponível em: <<https://doi.org/10.1007/s00034-019-01246-3>>. Citado 3 vezes nas páginas 60, 61 e 62.
- RUNGE, V. M.; SMOKER, W. R. K.; VALAVANIS, A. *Neuroradiology: The Essentials with MR and CT*. New York: Thieme Medical Publishers, 2015. ISBN 978-1-60406-916-7. Citado na página 16.
- RUSSELL, S. J.; NORVIG, P. *Artificial intelligence a modern approach*. [S.l.]: London, 2010. Citado na página 20.
- SACHDEVA, J.; SHARMA, D.; AHUJA, C. K. Comparative Analysis of Different Deep Convolutional Neural Network Architectures for Classification of Brain Tumor on Magnetic Resonance Images. *Archives of Computational Methods in Engineering*, Springer, v. 31, n. 4, p. 1959–1978, 2024. Citado na página 2.
- SAHOO, S.; MISHRA, S.; PANDA, B.; BHOI, A. K.; BARSOCCHI, P. An Augmented Modulated Deep Learning Based Intelligent Predictive Model for Brain Tumor Detection Using GAN Ensemble. *Sensors*, v. 23, n. 15, 2023. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/23/15/6930>>. Citado 2 vezes nas páginas 27 e 64.
- SAMUEL, A. L. Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, v. 3, n. 3, p. 210–229, 1959. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5392560>>. Citado na página 21.
- SCHULZ, M.-a.; YEO, B. T. T.; VOGELSTEIN, J. T.; MOURAO-MIRANADA, J.; KATHER, J. N.; KORDING, K.; RICHARDS, B.; BZDOK, D. Different scaling of linear models and deep learning in UKBiobank brain images versus machine-learning datasets. *Nature Communications*, Springer US, v. 11, n. 1, p. 4238, Agosto 2020. ISSN 2041-1723. Disponível em: <<http://dx.doi.org/10.1038/s41467-020-18037-zhttps://www.nature.com/articles/s41467-020-18037-z>>. Citado 2 vezes nas páginas 3 e 26.

SHALEV-SHWARTZ, S.; BEN-DAVID, S. *Understanding Machine Learning - From Theory to Algorithms*. [S.l.]: Cambridge University Press, 2014. I-XVI, 1-397 p. ISBN 978-1-10-705713-5. Citado na página 19.

SHAMSHAD, N.; SARWR, D.; ALMOGREN, A.; SALEEM, K.; MUNAWAR, A.; Ur Rehman, A.; BHARANY, S. Enhancing Brain Tumor Classification by a Comprehensive Study on Transfer Learning Techniques and Model Efficiency Using MRI Datasets. *IEEE Access*, IEEE, v. 12, p. 1–1, Junho 2024. ISSN 21693536. Citado na página 2.

SILLE, R.; CHOUDHURY, T.; SHARMA, A.; CHAUHAN, P.; TOMAR, R.; SHARMA, D. A novel generative adversarial network-based approach for automated brain tumour segmentation. *Medicina*, v. 59, n. 1, p. 119, 2023. Disponível em: <<https://doi.org/10.3390/medicina59010119>>. Citado na página 27.

SOLANKI, S.; SINGH, U. P.; CHOUHAN, S. S.; JAIN, S. Brain tumor detection and classification using intelligence techniques: An overview. *IEEE Access*, v. 11, p. 12870–12886, 2023. Citado na página 26.

SOMASUNDARAM, S.; GOBINATH, R. Current Trends on Deep Learning Models for Brain Tumor Segmentation and Detection - A Review. In: COM-IT-CON. *Proceedings of the International Conference on Machine Learning, Big Data, Cloud and Parallel Computing: Trends, Perspectives and Prospects, COMITCon 2019*. India, 2019. p. 217–221. Citado na página 23.

SWATI, Z. N. K.; ZHAO, Q.; KABIR, M.; ALI, F.; ALI, Z.; AHMED, S.; LU, J. Content-Based Brain Tumor Retrieval for MR Images Using Transfer Learning. *IEEE Access*, IEEE, v. 7, n. c, p. 17809–17822, 2019. ISSN 2169-3536. Disponível em: <<https://ieeexplore.ieee.org/document/8611216/>>. Citado 3 vezes nas páginas 60, 61 e 62.

TALUKDER, M. A.; ISLAM, M. M.; UDDIN, M. A.; AKHTER, A.; PRAMANIK, M. A. J.; ARYAL, S.; ALMOYAD, M. A. A.; HASAN, K. F.; MONI, M. A. An efficient deep learning model to categorize brain tumor using reconstruction and fine-tuning. *Expert Systems with Applications*, Elsevier Ltd, v. 230, p. 120534, Maio 2023. ISSN 09574174. Disponível em: <<https://doi.org/10.1016/j.eswa.2023.120534><http://arxiv.org/abs/2305.12844><https://linkinghub.elsevier.com/retrieve/pii/S0957417423010369>>. Citado 3 vezes nas páginas 59, 60 e 62.

TANDEL, G. S.; BISWAS, M.; KAKDE, O. G.; TIWARI, A.; SURI, H. S.; TURK, M.; LAIRD, J. R.; ASARE, C. K.; ANKRAH, A. A.; KHANNA, N. N.; MADHUSUDHAN, B. K.; SABA, L.; SURI, J. S. A Review on a Deep Learning Perspective in Brain Cancer Classification. *Cancers*, v. 11, n. 1, 2019. ISSN 2072-6694. Disponível em: <<https://www.mdpi.com/2072-6694/11/1/111>>. Citado 4 vezes nas páginas 2, 3, 17 e 26.

UCSF - University of California, San Francisco. *Imaging Data 101: Introduction to DICOM*. 2024. <<https://radiology.ucsf.edu/research/core-services/imaging-data-101>>. Acesso em: 10 set. 2025. Citado na página 18.

VAIYAPURI, T.; JAIGANESH, M.; AHMAD, S.; ABDELJABER, H. A.; YANG, E.; JEONG, S. yong. Ensemble Learning Driven Computer-Aided Diagnosis Model for Brain Tumor Classification on Magnetic Resonance Imaging. *IEEE Access*, IEEE, v. 11, p. 91398–91406, Agosto 2023. ISSN 21693536. Citado na página 61.

- VURE, R. B.; PAPPALA, L. K. Enhanced brain tumor classification framework using deep learning. *Scientific Reports*, v. 15, n. 1, p. 35814, 2025. ISSN 2045-2322. Disponível em: <<https://doi.org/10.1038/s41598-025-19882-y>>. Citado 2 vezes nas páginas 61 e 62.
- WAGEH, M.; AMIN, K.; ALGARNI, A. D.; HAMAD, A. M.; IBRAHIM, M. Brain Tumor Detection Based on Deep Features Concatenation and Machine Learning Classifiers with Genetic Selection. *IEEE Access*, Agosto 2024. ISSN 21693536. Citado na página 2.
- WANG, G.; JACOB, M.; MOU, X.; SHI, Y.; ELDAR, Y. C. Deep tomographic image reconstruction: Yesterday, today, and tomorrow—editorial for the 2nd special issue “machine learning for image reconstruction”. *IEEE Transactions on Medical Imaging*, v. 40, n. 11, p. 2956–2964, 2021. Citado 2 vezes nas páginas 25 e 26.
- WERNICK, M. N.; YANG, Y.; BRANKOV, J. G.; YOURGANOV, G.; STROTHER, S. C. Machine Learning in Medical Imaging. *IEEE SIGNAL PROCESSING MAGAZINE*, Julho 2010. Citado 2 vezes nas páginas 19 e 20.
- YANG, W. L.; SU, X. R.; LI, S.; ZHAO, K. Y.; YUE, Q. Utilizing machine-learning techniques on mri radiomics to identify primary tumors in brain metastases. *Frontiers in Neurology*, Frontiers Media SA, v. 15, 2024. ISSN 16642295. Citado na página 2.
- ZHANG, W. J.; CHEN, W. T.; LIU, C. H.; CHEN, S. W.; LAI, Y. H.; YOU, S. D. Feasibility Study of Detecting and Segmenting Small Brain Tumors in a Small MRI Dataset with Self-Supervised Learning. *Diagnostics*, Multidisciplinary Digital Publishing Institute (MDPI), v. 15, Fevereiro 2025. ISSN 20754418. Citado na página 2.
- ZHOU, Z.; MA, A.; FENG, Q.; WANG, R.; CHENG, L.; CHEN, X.; YANG, X.; LIAO, K.; MIAO, Y.; QIU, Y. Super-resolution of brain tumor mri images based on deep learning. *Journal of Applied Clinical Medical Physics*, Wiley, v. 23, n. 11, p. 1–13, 2022. Citado na página 27.
- ZULFIQAR, F.; Ijaz Bajwa, U.; MEHMOOD, Y. Multi-class classification of brain tumor types from MR images using EfficientNets. *Biomedical Signal Processing and Control*, Elsevier Ltd, v. 84, p. 104777, Março 2023. Disponível em: <<https://doi.org/10.1016/j.bspc.2023.104777><https://linkinghub.elsevier.com/retrieve/pii/S1746809423002100>>. Citado 3 vezes nas páginas 59, 60 e 62.