

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA – CÂMPUS DE ILHA SOLTEIRA PROGRAMA
DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

ANDRÉS IVÁN ATOCHE GALARRETA

**APLICAÇÃO DE MODELOS DE DEEP LEARNING PARA A DETECÇÃO DO
CÂNCER DE PULMÃO**

**Ilha Solteira - SP
2024**



ANDRÉS IVÁN ATOCHE GALARRETA

APLICAÇÃO DE MODELOS DE DEEP LEARNING PARA A DETECÇÃO DO
CÂNCER DE PULMÃO

Dissertação apresentada à Faculdade de Engenharia do Campus de Ilha Solteira - UNESP como parte dos requisitos para obtenção do título de Mestrado em Engenharia Elétrica..
Especialidade: Automação.

Prof. Dra. Anna Diva Plasencia Lotufo Orientadora
Orientador

Ilha Solteira - SP
2024

FICHA CATALOGRÁFICA
Desenvolvido pela Diretoria Técnica de Biblioteca e Documentação

A881a Atoche Galarreta, Andrés Iván.
Aplicação de modelos de *deep learning* para a detecção do câncer de pulmão / Andrés Iván Atoche Galarreta. -- Ilha Solteira: [s.n.], 2024
81 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2024

Orientador: Anna Diva Plasencia Lotufo
Coorientador: Leonardo Garcia
Inclui bibliografia

1. Câncer de pulmão. 2. *Deep learning*. 3. Imagens médicas. 4. *Transfer learning*. 5. Redes convolucionais.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: UTILIZAÇÃO DE MODELOS DE *DEEP LEARNING* PARA A DETECÇÃO DO CÂNCER DE PULMÃO

AUTOR: ANDRÉS IVÁN ATOCHE GALARRETA

ORIENTADORA: ANNA DIVA PLASENCIA LOTUFO

Aprovado como parte das exigências para obtenção do Título de Mestre em , área: Automação pela Comissão Examinadora:



Documento assinado digitalmente
ANNA DIVA PLASENCIA LOTUFO
Data: 10/05/2024 10:49:17-0300
Verifique em <https://validar.itl.gov.br>

Profa. Dra. ANNA DIVA PLASENCIA LOTUFO (Participação Presencial)
Departamento de Engenharia Eletrica / Faculdade de Engenharia de Ilha Solteira - UNESP

Profa. Dra. MARA LUCIA MARTINS LOPES (Participação Presencial)
Departamento de Matematica / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. CARLOS ROBERTO DOS SANTOS JÚNIOR (Participação Presencial)
Campus de Hortolândia / Instituto Federal de Educação, Ciência e Tecnologia de São Paulo - IFSP

Ilha Solteira, 13 de março de 2024

“É dedicado ao meu pai Andrés, à minha mãe Teresa, às minhas irmãs Any e Vane, e ao meu tio Agustín.”

AGRADECIMENTOS

Quero expressar meu sincero agradecimento a todas as pessoas que foram parte fundamental no desenvolvimento e conclusão deste projeto de dissertação de mestrado. Em especial, quero reconhecer o apoio incondicional do meu pai, Andrés, cuja sabedoria e incentivo constante têm sido meu farol nesta jornada acadêmica.

Às minhas irmãs, Any e Vane, agradeço por seu amor, paciência e compreensão durante as longas horas que passei dedicado a este trabalho. Seu apoio emocional tem sido minha força motriz, e sou profundamente grato por estarem sempre ao meu lado. Também gostaria de mencionar meu tio Agustin, por estar sempre conosco.

Gostaria também de agradecer de forma muito especial à minha orientadora Anna Diva, pela confiança, pelos conselhos, por estar sempre pronta a me dar todo o apoio necessário para que eu tivesse um bom desempenho em Ilha Solteira. Também gostaria de expressar meu agradecimento à professora Mara e ao professor Minucci pelo seu apoio. Da mesma forma, ao time do Sintel, especialmente à Paula e Leonardo, por seus conselhos e recomendações.

Gostaria de agradecer ao Sergio por seu inestimável apoio durante minha estada. Também ao Paulo por suas recomendações.

Ao pessoal da biblioteca, em especial à Larissa e Marília, por sempre me proporcionarem facilidades para estudar. A Junior e Gianina por me oferecerem todo o suporte no trabalho para que eu possa continuar meus estudos, assim como à Catherine pelo apoio no trabalho e por me proporcionar todas as facilidades para estudar. E a toda a comunidade de pós-graduação.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

RESUMO

Na América Latina, nos últimos anos, o câncer de pulmão emergiu como uma das principais causas de mortalidade. Segundo estimativas de 2023, no Brasil, esse tipo de câncer ocupa o terceiro lugar em incidência entre os homens e o quarto entre as mulheres. Essa problemática é agravada devido ao acesso limitado aos serviços de saúde, especialmente entre as pessoas em situação de pobreza, que são mais afetadas. Esse panorama apresenta um desafio significativo para a nossa sociedade. Com o objetivo de abordar essa questão, este estudo concentrou-se na avaliação do desempenho de cinco modelos diferentes de redes convolucionais aplicadas ao diagnóstico do câncer a partir de imagens médicas. Para isso, utilizou-se um conjunto de dados composto por tomografias computadorizadas de pulmões classificadas em três estados: maligno, benigno e normal. Utilizando a técnica de aprendizado de transferência, esses cinco modelos foram treinados e avaliados sob diferentes cenários (experimentos). Os resultados obtidos revelaram que o modelo InceptionV3 demonstrou o melhor desempenho em termos de precisão. Por outro lado, o modelo Xception alcançou uma precisão superior a 90% em seis de oito cenários avaliados.

Palavras-chave: Câncer de pulmão; classificação; aprendizado de transferência; aprendizado profundo; inceptionv3; Xception; imagens médicas.

ABSTRACT

In Latin America, in recent years, lung cancer has emerged as one of the leading causes of mortality. According to estimates from 2023, in Brazil, this type of cancer ranks third in incidence among men and fourth among women. This issue is exacerbated due to limited access to healthcare services, especially among individuals living in poverty, who are disproportionately affected. This landscape presents a significant challenge for our society. In order to address this issue, this study focused on evaluating the performance of five different convolutional network models applied to cancer diagnosis using medical imaging. The aim was to determine which models respond best to lung cancer diagnosis. To achieve this, a dataset consisting of lung computed tomography scans classified into three states—malignant, benign, and normal—was utilized. Employing transfer learning, these five models were trained and evaluated under different scenarios. The results obtained revealed that the InceptionV3 model demonstrated the best performance in terms of accuracy. On the other hand, the Xception model achieved an accuracy exceeding 90% in six out of the eight evaluated scenarios.

Keywords: Lung cancer; classification; transfer learning; deep learning; inceptionv3; xception; medical images.

LISTA DE FIGURAS

Figura 1 – Estado normal.	21
Figura 2 – Câncer maligno.	22
Figura 3 – Histórico da “ <i>Deep Learning</i> ”.	24
Figura 4 – Ilustração dos usos de uma memória associativa para completar padrões e corrigir erros.	25
Figura 5 – Representação matemática de um círculo.	27
Figura 6 – Conjunto de núcleos.	27
Figura 7 – Diferentes estágios de processamento em uma camada convolucional.	28
Figura 8 – Esquemático dos métodos de agrupamento Max, médio e soma.	28
Figura 9 – Camadas totalmente conectadas.	29
Figura 10 – Arquitetura da <i>ResNet50</i>	30
Figura 11 – Arquitetura da <i>VGG19</i>	31
Figura 12 – Arquitetura da <i>InceptionV3</i>	31
Figura 13 – Arquitetura da <i>Xception</i>	32
Figura 14 – Arquitetura da <i>DenseNet201</i>	33
Figura 15 – Aprendizagem por transferência.	34
Figura 16 – Ambiente do Colaboratory.	37
Figura 17 – Matriz de confusão.	39
Figura 18 – Matriz de Confusão - <i>ResNet50</i>	42
Figura 19 – Curva ROC - <i>ResNet50</i>	42
Figura 20 – Matriz de Confusão - <i>VGG19</i>	42
Figura 21 – Curva ROC - <i>VGG19</i>	42
Figura 22 – Matriz de Confusão - <i>DenseNet201</i>	43
Figura 23 – Curva ROC - <i>DenseNet201</i>	43
Figura 24 – Matriz de Confusão - <i>InceptionV3</i>	43
Figura 25 – Curva ROC - <i>InceptionV3</i>	43
Figura 26 – Matriz de Confusão - <i>Xception</i>	44
Figura 27 – Curva ROC - <i>Xception</i>	44
Figura 28 – Matriz de Confusão - <i>ResNet50</i>	45
Figura 29 – Curva ROC - <i>ResNet50</i>	45
Figura 30 – Matriz de Confusão - <i>VGG19</i>	45
Figura 31 – Curva ROC - <i>VGG19</i>	45
Figura 32 – Matriz de Confusão - <i>DenseNet201</i>	46
Figura 33 – Curva ROC - <i>DenseNet201</i>	46
Figura 34 – Matriz de Confusão - <i>InceptionV3</i>	46
Figura 35 – Curva ROC - <i>InceptionV3</i>	46

Figura 36 – Matriz de Confusão - <i>Xception</i>	47
Figura 37 – Curva ROC - <i>Xception</i>	47
Figura 38 – Matriz de Confusão - <i>ResNet50</i>	48
Figura 39 – Curva ROC - <i>ResNet50</i>	48
Figura 40 – Matriz de Confusão - <i>VGG19</i>	48
Figura 41 – Curva ROC - <i>VGG19</i>	48
Figura 42 – Matriz de Confusão - <i>DenseNet201</i>	49
Figura 43 – Curva ROC - <i>DenseNet201</i>	49
Figura 44 – Matriz de Confusão - <i>InceptionV3</i>	49
Figura 45 – Curva ROC - <i>InceptionV3</i>	49
Figura 46 – Matriz de Confusão - <i>Xception</i>	50
Figura 47 – Curva ROC - <i>Xception</i>	50
Figura 48 – Matriz de Confusão - <i>ResNet50</i>	51
Figura 49 – Curva ROC - <i>ResNet50</i>	51
Figura 50 – Matriz de Confusão - <i>VGG19</i>	51
Figura 51 – Curva ROC - <i>VGG19</i>	51
Figura 52 – Matriz de Confusão - <i>DenseNet201</i>	52
Figura 53 – Curva ROC - <i>DenseNet201</i>	52
Figura 54 – Matriz de Confusão - <i>InceptionV3</i>	52
Figura 55 – Curva ROC - <i>InceptionV3</i>	52
Figura 56 – Matriz de Confusão - <i>Xception</i>	53
Figura 57 – Curva ROC - <i>Xception</i>	53
Figura 58 – Matriz de Confusão - <i>ResNet50</i>	54
Figura 59 – Curva ROC - <i>ResNet50</i>	54
Figura 60 – Matriz de Confusão - <i>VGG19</i>	54
Figura 61 – Curva ROC - <i>VGG19</i>	54
Figura 62 – Matriz de Confusão - <i>DenseNet201</i>	55
Figura 63 – Curva ROC - <i>DenseNet201</i>	55
Figura 64 – Matriz de Confusão - <i>InceptionV3</i>	55
Figura 65 – Curva ROC - <i>InceptionV3</i>	55
Figura 66 – Matriz de Confusão - <i>Xception</i>	56
Figura 67 – Curva ROC - <i>Xception</i>	56
Figura 68 – Matriz de Confusão - <i>ResNet50</i>	57
Figura 69 – Curva ROC - <i>ResNet50</i>	57
Figura 70 – Matriz de Confusão - <i>VGG19</i>	57
Figura 71 – Curva ROC - <i>VGG19</i>	57
Figura 72 – Matriz de Confusão - <i>DenseNet201</i>	58
Figura 73 – Curva ROC - <i>DenseNet201</i>	58
Figura 74 – Matriz de Confusão - <i>InceptionV3</i>	58

Figura 75 – Curva ROC - <i>InceptionV3</i>	58
Figura 76 – Matriz de Confusão - <i>Xception</i>	59
Figura 77 – Curva ROC - <i>Xception</i>	59
Figura 78 – Matriz de Confusão - <i>ResNet50</i>	60
Figura 79 – Curva ROC - <i>ResNet50</i>	60
Figura 80 – Matriz de Confusão - <i>VGG19</i>	60
Figura 81 – Curva ROC - <i>VGG19</i>	60
Figura 82 – Matriz de Confusão - <i>DenseNet201</i>	61
Figura 83 – Curva ROC - <i>DenseNet201</i>	61
Figura 84 – Matriz de Confusão - <i>InceptionV3</i>	61
Figura 85 – Curva ROC - <i>InceptionV3</i>	61
Figura 86 – Matriz de Confusão - <i>Xception</i>	62
Figura 87 – Curva ROC - <i>Xception</i>	62
Figura 88 – Matriz de Confusão - <i>ResNet50</i>	63
Figura 89 – Curva ROC - <i>ResNet50</i>	63
Figura 90 – Matriz de Confusão - <i>VGG19</i>	63
Figura 91 – Curva ROC - <i>VGG19</i>	63
Figura 92 – Matriz de Confusão - <i>DenseNet201</i>	64
Figura 93 – Curva ROC - <i>DenseNet201</i>	64
Figura 94 – Matriz de Confusão - <i>InceptionV3</i>	64
Figura 95 – Curva ROC - <i>InceptionV3</i>	64
Figura 96 – Matriz de Confusão - <i>Xception</i>	65
Figura 97 – Curva ROC - <i>Xception</i>	65

LISTA DE TABELAS

Tabela 1 – Distribuição proporcional dos cinco tipos de câncer mais incidentes estimados para 2023 exceto pele não melanoma em homens*	20
Tabela 2 – Distribuição proporcional dos cinco tipos de câncer mais incidentes estimados para 2023 exceto pele não melanoma em homens*	20
Tabela 3 – Distribuição da população segurada, casos diagnosticados de câncer e prevalências estimadas no período de 2019 a 2022 em EsSalud.	21
Tabela 4 – Resumo dos Modelos de <i>CNN</i>	33
Tabela 5 – Tabela de cenários com seus respectivos parâmetros.	41
Tabela 6 – Parâmetros usados no experimento 1.	42
Tabela 7 – Parâmetros usados no experimento 2.	44
Tabela 8 – Parâmetros usados no experimento 3.	47
Tabela 9 – Parâmetros usados no experimento 4.	50
Tabela 10 – Parâmetros usados no experimento 5.	53
Tabela 11 – Parâmetros usados no experimento 6.	56
Tabela 12 – Parâmetros usados no experimento 7.	59
Tabela 13 – Parâmetros usados no experimento 8.	62
Tabela 14 – Resultados para o Modelo <i>ResNet50</i>	66
Tabela 15 – Resultados para o Modelo <i>ResNet50</i>	66
Tabela 16 – Resultados para o Modelo <i>VGG19</i>	66
Tabela 17 – Resultados para o Modelo <i>VGG19</i>	67
Tabela 18 – Resultados para o Modelo <i>DenseNet201</i> , experimento 1 ao experimento 4.	67
Tabela 19 – Resultados para o Modelo <i>DenseNet201</i> , experimento 5 ao experimento 8.	67
Tabela 20 – Resultados para o Modelo <i>InceptionV3</i>	67
Tabela 21 – Resultados para o Modelo <i>InceptionV3</i>	67
Tabela 22 – Resultados para o Modelo <i>Xception</i>	68
Tabela 23 – Resultados para o Modelo <i>Xception</i>	68
Tabela 24 – Resultados dos modelos com diferentes cenários.	68
Tabela 25 – Resultados dos modelos com diferentes cenários.	69
Tabela 26 – Tabela de cenários com seus respectivos parâmetros.	69
Tabela 27 – Resultados do modelo com a métrica de sensibilidade (<i>recall</i>).	69
Tabela 28 – Resultados do modelo com a métrica de precisão.	70
Tabela 29 – Resultados do modelo com a métrica de especificidade.	70
Tabela 30 – Resultados do modelo com a métrica de <i>F1-score</i>	70
Tabela 31 – Tabela de cenários com seus respectivos parâmetros.	71
Tabela 32 – Resultados do modelo com a métrica de sensibilidade (<i>recall</i>).	71
Tabela 33 – Resultados do modelo com a métrica de precisão.	72

Tabela 34 – Resultados do modelo com a métrica de especificidade.	72
Tabela 35 – Resultados do modelo com a métrica de <i>F1-score</i>	72
Tabela 36 – Tabela de cenários com seus respectivos parâmetros.	73
Tabela 37 – Resultados do modelo com a métrica de sensibilidade (<i>recall</i>).	73
Tabela 38 – Resultados do modelo com a métrica de precisão.	73
Tabela 39 – Resultados do modelo com a métrica de especificidade.	74
Tabela 40 – Resultados do modelo com a métrica de <i>F1-score</i>	74

LISTA DE ABREVIATURAS E SIGLAS

ACS	<i>American Cancer Society</i>
AUC	<i>Area Under the Curve</i>
CNN	<i>Convolutional Neural Network</i>
CONITEC	Comissão Nacional de Incorporação de Tecnologias no Sistema Único de Saúde
ESSALUD	Seguro Social de Salud
FN	Falso Negativo
FP	Falso Positivo
HU	Unidades Hounsfield
INCA	Instituto Nacional de Câncer
MC	<i>Mayo Clinic</i>
OPS	Organização Pan-Americana da Saúde
PX	<i>Pixel</i>
RNA	Rede Neural Artificial
ROC	<i>Receiver Operating Characteristic</i> SBRT
Sociedade Brasileira de Radioterapia	SVM
	<i>Support Vector Machine</i>
TC	<i>Tomografia computadorizada</i>
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

SUMÁRIO

1	INTRODUÇÃO	16
1.1	JUSTIFICATIVA	17
1.2	OBJETIVO	17
1.3	LIMITAÇÕES	18
2	CÂNCER	19
2.1	CÂNCER DE PULMÃO	19
2.1.1	Estatísticas	20
2.1.2	Diagnóstico	21
2.1.3	Tomografia computadorizada - TC	22
2.1.4	Fatores de risco	22
3	INTELIGÊNCIA ARTIFICIAL	23
3.1	<i>DEEP LEARNING</i>	24
3.2	REDES NEURAIS CONVOLUCIONAIS	26
3.3	MODELOS DE REDES NEURAIS CONVOLUCIONAIS	29
3.3.1	ResNet50	29
3.3.2	VGG19	30
3.3.3	InceptionV3	31
3.3.4	Xception	32
3.3.5	DenseNet201	32
3.4	APRENDIZADO DE TRANSFERÊNCIA	33
4	APRENDIZAGEM PROFUNDO APLICADO AO DIAG-NÓSTICO DE CÂNCER DE PULMÃO	35
4.1	COLETA DE DADOS	35
4.2	PRÉ-PROCESSAMENTO DE IMAGENS	36
4.3	TREINAMENTO DOS MODELOS	37
4.4	AVALIAÇÃO DOS MODELOS	38
4.5	ANÁLISE DOS RESULTADOS	40
5	RESULTADOS	41
5.1	EXPERIMENTO 1	41
5.2	EXPERIMENTO 2	44
5.3	EXPERIMENTO 3	37
5.4	EXPERIMENTO 4	50
5.5	EXPERIMENTO 5	53
5.6	EXPERIMENTO 6	56
5.7	EXPERIMENTO 7	59
5.8	EXPERIMENTO 8	62
6	DISCUSSÃO	66
7	CONCLUSÕES	75
	REFERÊNCIAS	77

1 INTRODUÇÃO

Na América Latina, nos últimos anos, o câncer de pulmão emergiu com uma alta taxa de mortalidade (OPS, 2023b). A falta de infraestrutura médica, profissionais de saúde e acesso aos sistemas de saúde tem agravado o avanço do câncer na maioria dos países (OPS, 2023a). A situação é ainda mais sombria para pessoas em situação de pobreza, considerando a crise econômica que atravessa a América Latina, especialmente para aquelas com menos recursos econômicos.

No Brasil, essa realidade não é diferente, o câncer de pulmão apresenta uma alta taxa de mortalidade (Brasil, 2023). Da mesma forma, muitas pessoas não têm acesso aos serviços médicos devido à falta de infraestrutura (SBRT, 2023). Segundo o Instituto Nacional do Câncer no Brasil, estima-se que em 2023 haverá 18.020 novos casos em homens e 14.540 novos casos em mulheres (Brasil, 2023a).

Diante desse cenário preocupante, cada vez mais têm sido utilizadas novas tecnologias, como o aprendizado profundo (*deep learning*), para encontrar formas mais eficazes de diagnosticar o câncer, principalmente em estágios iniciais. Essas tecnologias permitem analisar grandes conjuntos de dados médicos, como imagens de tomografias computadorizadas, radiografias e biópsias, para identificar padrões e características que possam indicar a presença de câncer de pulmão.

Essa abordagem também tem possibilitado pesquisas em todo o mundo, como no estudo “*ProCAN: Progressive Growing Channel Attentive NonLocal Network for Lung Nodule Classification*” de (Al-Shabi; Shak; Tan, 2022), os autores propuseram um novo modelo para classificação de nódulos pulmonares. Resultados demonstraram que o modelo ProCAN superou os métodos convencionais, alcançando uma precisão de 98,05% e uma sensibilidade de 95,28%.

Além disso, o estudo “*Review of lung cancer detection and classification using deep learning*” de (Agarwal, 2023), discute arquiteturas de aprendizado profundo, conjuntos de dados, técnicas de pré-processamento e métricas de avaliação utilizadas. Os resultados mostraram uma precisão geral de 92,3%, sensibilidade de 89,7% e especificidade de 94,5%.

No Brasil, pesquisas também têm sido realizadas, como o estudo “*Utilização de Redes Neurais Convolucionais na detecção, segmentação e classificação de núcleos celulares para identificação de aneuploidia*” de (Buschetto, 2021), que apresenta um fluxo completo para automação do processo de segmentação, detecção e/ou classificação de núcleos em lâminas preparadas com tinta de Feulgen, utilizando redes convolucionais para detectar aneuploidia em exames de citometria de DNA. Embora a detecção e segmentação tenham apresentado bom desempenho, diferenças nas classes indicam que os algoritmos ainda não estão prontos para implementação clínica.

Nesse contexto, o objetivo deste estudo foi avaliar o desempenho de cinco modelos diferentes de redes convolucionais aplicadas ao diagnóstico de câncer de pulmão por meio de imagens médicas. Usando um conjunto de dados de tomografias computadorizadas de pulmões classificadas em três estados, maligno, benigno e normal. Esses cinco modelos são: *ResNet50*, *VGG19*, *Inception*, *Xception* e *DenseNet201*. Os critérios para a seleção foram três: representatividade, desempenho e disponibilidade. A **representatividade** foi considerada ao analisar diferentes modelos com diversas estruturas e características. O segundo critério, o **desempenho**, baseou-se em estudos prévios que avaliaram individualmente os modelos

selecionados. Finalmente, a disponibilidade foi um fator chave, pois eram necessários modelos que estivessem disponíveis gratuitamente ou de fácil acesso.

Os resultados indicaram que o modelo *InceptionV3* teve o melhor desempenho, enquanto o modelo *Xception* obteve resultados superiores a 90% em seis de oito cenários avaliados. Considerando esses resultados, *InceptionV3* e *Xception* seriam modelos prioritários para futuros projetos de diagnóstico de câncer.

1.1 JUSTIFICATIVA

A importância da detecção precoce dessa doença reside no fato de que os pacientes podem receber um tratamento mais efetivo, com maiores chances de cura e menores custos. Além disso, as redes neurais convolucionais permitem identificar padrões complexos nas imagens médicas, o que pode ajudar os médicos a tomar decisões mais precisas e rápidas no diagnóstico e tratamento do câncer de pulmão.

Foram realizados estudos que mostraram que o uso de modelos de *deep learning* reduz a quantidade de dias no diagnóstico de detecção de câncer de pulmão, ao mesmo tempo em que detecta novos casos que os especialistas não puderam identificar inicialmente (Chiu *et al.*, 2022)

Em suma, a aplicação de técnicas de inteligência artificial, como as redes neurais convolucionais, na detecção de câncer de pulmão a partir de imagens médicas é uma demonstração de maestria no campo da medicina. A detecção precoce dessa doença pode salvar vidas e diminuir custos, tornando-se, portanto, um campo de pesquisa de importância vital no âmbito da saúde pública.

1.2 OBJETIVO

O objetivo principal deste estudo é realizar uma análise abrangente dos principais modelos na identificação do câncer de pulmão por meio do uso de imagens médicas e realizar uma comparação de seus resultados.

Esses modelos são:

- *ResNet50*.
- *VGG19*.
- *InceptionV3*.
- *Xception*.
- *DenseNet201*.

1.3 LIMITAÇÕES

Para analisar a informação, utilizou-se uma plataforma web do *Google* chamada *Google Colab* . A principal limitação é que a versão gratuita não oferece uma capacidade computacional adequada e, muitas vezes, o processo é interrompido. A versão paga pode, por vezes, estar fora do alcance do aluno.

2 CÂNCER

Nesta seção, serão desenvolvidos os conceitos teóricos básicos para uma compreensão completa da pesquisa. Primeiramente, serão revisados os conceitos relacionados ao câncer, câncer de pulmão, estágios, etc. A seguir, serão abordados os temas relacionados à Inteligência Artificial, Aprendizado de Máquina, *Deep Learning*, redes convolucionais, principais modelos de redes convolucionais, bem como sua aplicação em imagens médicas na detecção do câncer.

Ao falar sobre câncer, o espectro é bastante amplo, com mais de 100 doenças malignas diferentes que se caracterizam pelo crescimento desordenado de suas células. Essas células podem invadir tecidos adjacentes ou distantes (Brasil, 2023a).

Devido à rápida divisão dessas células, elas tendem a ser muito agressivas e podem formar tumores em várias partes do corpo. Para cada tipo de célula no corpo, corresponde um tipo diferente de câncer. Por exemplo, quando se localizam nos tecidos epiteliais, são denominados carcinomas, enquanto, por outro lado, quando se localizam nos tecidos conjuntivos, como ossos, músculos ou cartilagens, são chamados sarcomas, de acordo com o INCA (Brasil, 2023a).

Existem fatores internos e externos que podem causar câncer; entre os fatores internos estão os hormônios, condições imunológicas e mutações genéticas. Enquanto os fatores externos incluem substâncias químicas, radiação e vírus (Brasil, 2022).

É importante ressaltar que a maioria dos tipos de câncer não são hereditários. Existem casos muito específicos que são herdados, como o retinoblastoma, que é um tipo de câncer ocular que ocorre em crianças. No entanto, existem fatores genéticos que predisõem certas pessoas a serem mais suscetíveis a agentes ambientais causadores de câncer (Brasil, 2024).

2.1 CÂNCER DE PULMÃO

O Conitec define o câncer de pulmão como parte de um grupo de carcinomas que tem origem na multiplicação de células anormais que revestem a parte inferior da traqueia, dos brônquios, dos bronquíolos, dos alvéolos e dos pulmões (Brasil, 2023b).

Os tumores benignos geralmente crescem muito lentamente, não se espalham para outras partes do corpo nem invadem os tecidos circundantes. Geralmente, não costumam gerar sintomas a menos que atinjam um tamanho considerável que provoque pressão sobre outras estruturas (ACS, 2024).

Os tumores malignos (câncer) podem crescer rapidamente e de forma descontrolada.

Eles podem se expandir e se propagar para áreas próximas. Suas células podem se desprender, viajar pelo sistema sanguíneo ou linfático e começar a crescer em outras partes do corpo. Quando isso acontece, é chamado de metástase (ACS, 2024).

2.1.1 Estatísticas

Nesta seção, serão apresentadas algumas estatísticas relevantes sobre o câncer de pulmão.

No Brasil, estima-se que, entre 2023 e 2025, haverá 32560 novos casos relacionados ao câncer de traqueia, brônquios e pulmão e que, até 2023, haverá 18020 casos em homens e 14540 em mulheres, representando 17,06 novos casos por 100.000 homens e 13,15 por 100.000 mulheres. Os detalhes estão na Tabela 1 e Tabela 2.

Tabela 1 – Distribuição proporcional dos cinco tipos de câncer mais incidentes estimados para 2023 exceto pele não melanoma em homens*.

Localização Primária	Casos
Próstata	71730
Cólon e reto	21970
yellow Traqueia, brônquio e pulmão	18020
Estômago	13340
Cavidade oral	10900

*Números arredondados.

Fonte: (Brasil, 2023b).

Tabela 2 – Distribuição proporcional dos cinco tipos de câncer mais incidentes estimados para 2023 exceto pele não melanoma em homens*.

Localização Primária	Casos
Próstata	71730
Cólon e reto	21970
yellow Traqueia, brônquio e pulmão	18020
Estômago	13340
Cavidade oral	10900

*Números arredondados.

Fonte: (Brasil, 2023b).

Para o caso do Peru, os casos de câncer de pulmão têm aumentado, como é mostrado na seguinte Tabela 3.

Tabela 3 – Distribuição da população segurada, casos diagnosticados de câncer e prevalências estimadas no período de 2019 a 2022 em EsSalud.

Casos	2019	2020	2021	2022
câncer de pulmão	1729	2393	2846	3382


Fonte: Adaptado do (Garate; Becera; Osada, 2023).

2.1.2 Diagnóstico

A seguir, apresenta-se uma tabela resumo das etapas do diagnóstico do câncer de pulmão.

Testes de imagem: ma imagem de raio-X dos seus pulmões pode revelar uma massa ou nódulo anormal. Uma tomografia computadorizada pode revelar pequenas lesões em seus pulmões que podem não ser detectadas em um raio-X. A Figura 1 mostra uma imagem do estado normal (MC, 2023).

Figura 1 – Estado normal.



Fonte: Adaptado de Mahimkar (2024)

A Figura 2 mostra um caso de câncer maligno.

Figura 2 – Câncer maligno.



Fonte: Adaptado de Mahimkar (2024)

Citologia do escarro: O escarro produzido pela tosse também pode ser analisado sob o microscópio, pois pode revelar a presença de células cancerígenas no pulmão (MC, 2023).

Amostra de tecido (biópsia): Uma amostra de células anormais pode ser removida em um procedimento chamado biópsia (MC, 2023).

2.1.3 Tomografia computadorizada – TC

A tomografia computadorizada é um procedimento no qual raios-X são aplicados a um paciente a partir de diferentes ângulos ao redor do corpo. Com os dados obtidos, a informação é processada por um computador e é possível obter a seção transversal dos tecidos ou ossos. Essas imagens podem ser “empilhadas” para formar uma imagem em 3D. Dessa forma, é possível oferecer um maior detalhe do que as imagens tradicionais e facilitar a identificação de tumores (NATIONAL CANCER INSTITUTE, 2024).

2.1.4 Fatores de risco

O risco de contrair câncer e a mortalidade aumentam devido ao tabagismo, sendo a mortalidade 15 vezes maior em relação às pessoas que nunca fumaram. Outros fatores de risco incluem exposição a agentes químicos ou água contaminada, poluição do ar, infecções pulmonares recorrentes, doença pulmonar obstrutiva crônica, fatores genéticos e histórico familiar de câncer, todos favorecendo o desenvolvimento da doença (Brasil, 2022).

3 INTELIGÊNCIA ARTIFICIAL

A noção de Inteligência Artificial (IA) evoluiu significativamente desde sua conceituação inicial na década de 1950. John McCarthy, em 1955, durante a Conferência de Dartmouth usou pela primeira vez o termo Inteligência Artificial (McCarthy *et al.*, 2006), é definido como “a ciência e engenharia de fazer máquinas inteligentes” (Schofield, 2011).

Allen Newell e Herbert Simon, em 1958, apresentaram o “*Logic Theorist*” (Simon; Newell; Shaw, 1958), o primeiro programa de IA, projetado para simular habilidades de resolução de problemas humanos. Esse marco representou um avanço significativo ao demonstrar a capacidade das máquinas em lidar com problemas complexos.

Marvin Minsky, definiu a IA como “a ciência de fazer com que máquinas realizem coisas que requereriam inteligência se realizadas por seres humanos”. Essa definição destacou a capacidade das máquinas em imitar comportamentos inteligentes (Dennis, 2024).

A evolução não parou por aí. Ao longo do tempo, outros pesquisadores como Ray Kurzweil apresentaram perspectivas adicionais. Kurzweil, em seus escritos, considera a IA como “a criação de programas de computador que realizam tarefas que, se feitas com habilidade humana, seriam consideradas inteligentes”. Além disso, como futurista, previu que a singularidade, o ponto em que a IA ultrapassará a inteligência humana, ocorrerá por volta de 2045 (Lauder, 2017).

Outras abordagens:

Alan Turing, com sua proposta do famoso “Teste de Turing” em 1950, levantou a questão fundamental se as máquinas podem demonstrar um comportamento indistinguível do humano. Esse teste tornou-se um ponto de referência para avaliar a inteligência das máquinas.

As abordagens para a IA variaram ao longo do tempo. Alguns enfatizaram a fidelidade ao desempenho humano, enquanto outros preferiram uma definição abstrata e formal de inteligência, chamada racionalidade, que se refere a fazer o “correto”. Essas abordagens deram origem a diversas pesquisas e programas, desde a imitação da inteligência humana até a construção de agentes racionais que percebem seu ambiente e agem para alcançar seus objetivos.


Atualmente, a IA ressurgiu com grande proeminência; no entanto, sua definição evoluiu e se sofisticou com o tempo. A compreensão da IA vai além da mera simulação do comportamento humano, abrangendo a capacidade das máquinas de raciocinar, aprender e agir de forma autônoma, respaldada por abordagens científicas e de engenharia (Chowdhary, 2020).

Segundo Chowdhary “Inteligência Artificial envolve o uso de métodos baseados no comportamento inteligente dos seres humanos e de outros animais para resolver problemas complexos”, (Chowdhary, 2020).

3.1 DEEP LEARNING

Para uma melhor compreensão do contexto do aprendizado profundo, é examinada sua evolução ao longo dos anos, conforme proposto por (Kelleher, 2019) em seu livro “*Deep Learning*”, como pode ser visto na Figura 3.

Figura 3 – Histórico da “*Deep Learning*”.



Fonte: Adaptado de Kelleher (2019).

Kelleher divide essa evolução em três grandes estágios. O primeiro é conhecido como *Early Research: Threshold Logic Units* - pesquisa inicial: Unidades Lógicas de Limiar (desde o início dos anos 40 até meados dos anos 60), o segundo estágio é chamado de Conexionismo (desde o início dos anos 80 até meados dos anos 90) e aprendizado profundo (desde meados dos anos 2000 até o presente) (Kelleher, 2019).

Uma das características da primeira fase é que os modelos processavam entradas booleanas (Verdadeiro/Falso, 1/-1, 1/0) e também geravam saídas booleanas. Eles usavam funções de ativação de limiar e estavam restritos a uma única camada. Basicamente, o foco da pesquisa inicial era entender se os modelos computacionais baseados em neurônios

artificiais eram capazes de aprender relações lógicas como a conjunção ou a disjunção (Kelleher, 2019).

Para a segunda fase, chamada de conexionismo (*connectionism*), na década de 80, as críticas do final dos anos 60 foram reavaliadas como muito severas. E houve dois desenvolvimentos principais que revitalizaram o campo, primeiro as redes de *Hopfield* e o algoritmo de *backpropagation* (Kelleher, 2019). Em 1982, *John Hopfield* publicou um artigo descrevendo uma rede que poderia funcionar como uma memória associativa, na qual durante o treinamento, uma memória associativa aprendia um conjunto de padrões de entrada e, uma vez treinada, se uma versão corrompida de um dos padrões de entrada fosse apresentada à rede, ela seria capaz de regenerar o padrão completo corretamente. As memórias associativas são úteis para várias tarefas, incluindo o preenchimento de padrões e a correção de erros (Kelleher, 2019). O detalhe está na Figura 4.

Figura 4 – Ilustração dos usos de uma memória associativa para completar padrões e corrigir erros.

Training patterns	Pattern completion		
John**12May	Liz***?????	→	Liz***25Feb
Kerry*03Jan	???***10Mar	→	Des***10Mar
Liz***25Feb	Error correction		
Des***10Mar	Kerry*01Apr	→	Kerry*03Jan
Josef*13Dec	Jxsuf*13Dec	→	Josef*13Dec

Fonte: Kelleher (2019).

O segundo marco desta etapa foi o algoritmo de *backpropagation*, no qual, em 1986, um grupo de pesquisa em processamento distribuído em paralelo publicou dois livros, sendo o primeiro deles o capítulo 8 descrevendo o algoritmo, que indica que a *backpropagation* começa atribuindo pesos aleatórios a cada uma das conexões da rede. Em seguida, o algoritmo atualiza iterativamente os pesos na rede, apresentando instâncias de treinamento à rede e atualizando os pesos até que a rede funcione conforme o esperado (Kelleher, 2019).

Para esta terceira etapa, o primeiro registro do uso do termo “*deep learning*” foi atribuído a *Rina Dechter* (1986), embora seu trabalho não tenha sido usado para redes neurais. Quem o usou para esse fim foi Aizenberg, Aizenberg e Vandewalle (2016). O termo é usado para enfatizar que as redes sendo treinadas são muito mais profundas do que as anteriores (Kelleher, 2019). Um dos primeiros sucessos nesta etapa foi a pesquisa de *Geoffrey Hinton* e seus colegas, que demonstraram ser possível treinar uma rede neural profunda usando um processo conhecido como pré-treinamento em camadas *Greedy*. O pré-treinamento começa treinando uma única camada de neurônios que recebem diretamente

a entrada sem processamento. Uma forma popular de treinar essa única camada é usando *autoencoder*.

Na etapa contemporânea, Tom Taulli, autor do livro “*Artificial Intelligence Basics*” Taulli (2019), define o *Deep Learning* como um subcampo da aprendizagem de máquina. Esse tipo de sistema permite processar grandes volumes de dados para encontrar relações e padrões que muitas vezes os humanos são incapazes de detectar. A palavra “profundo” refere-se ao número de camadas ocultas na rede neural, as quais fornecem grande parte do poder de aprendizado.

Assim também, o aprendizado profundo foca em emular gradualmente o processo de aprendizagem de redes neurais artificiais (RNA) em áreas como processamento de imagens, reconhecimento de voz, compreensão e até mesmo na capacidade de tomar decisões autônomas. Em vez de imitar precisamente o funcionamento de neurônios reais, ele se baseia em princípios matemáticos gerais para aprender a reconhecer pessoas ou objetos em uma imagem e traduzir a fala de um idioma para outro por meio de exemplos. As tecnologias baseadas em aprendizado profundo revolucionaram a pesquisa em inteligência artificial, gerando resultados muito mais precisos em áreas como reconhecimento de voz, visão computacional, processamento de linguagem natural e robótica (Chowdhary, 2020).


3.2 REDES NEURAIIS CONVOLUCIONAIS

As redes neurais convolucionais são um tipo específico de arquitetura de redes neurais, desenvolvidas para analisar padrões espaciais, como imagens (Krohn, 2020). Esta modalidade utiliza uma operação matemática conhecida como convolução. Sua finalidade principal é a extração de características relevantes da imagem, como cores, bordas e texturas (Arif; Rahim, 2024).

Rothman (2020) explica a CNN com um exemplo:

Imagine a tarefa de representar o sol usando apenas um lápis comum e um pedaço de papel. O sol está brilhando intensamente, quase demasiado brilhante para olhar diretamente. Para isso, são usados óculos de sol com um filtro de redução de cor, uma das primeiras operações de uma rede neural convolucional. Depois de alguns segundos, desenha-se um círculo e adiciona-se um pouco de cinza no centro, aplicando um filtro de borda. O círculo é repassado várias vezes, reduzindo gradualmente o que é visto a uma representação matemática dele. No final, o desenho resultante é um círculo com um pouco de cinza no centro e algumas linhas representando os raios solares. Qualquer pessoa pode identificar que se trata de um desenho do sol. Foi possível transformar uma imagem a cores do sol em uma representação matemática como um círculo, semelhante à Figura 5 (Rothman, 2020).

Figura 5 – Representação matemática de um círculo.



Fonte: Rothman (2020).


O sol foi desenhado área por área, fazendo pequenos movimentos oculares para capturá-lo. Em seguida, foi realizada uma abstração para representar o sol em um papel.

Foi aplicado um filtro de redução de cor. Foi tentado desenhar o sol. Em seguida, foi aplicado um filtro de bordas. O círculo foi repassado várias vezes para torná-lo mais reconhecível.

O funcionamento é semelhante quando um documento é lido. Inicia-se da direita para a esquerda, por seções, e depois para baixo até completar todo o documento. Essa grade vermelha é chamada de filtro ou kernel.

As **camadas convolucionais** são o bloco de construção principal da arquitetura de *CNN*. Nessas camadas, um conjunto de filtros é aplicado nas imagens de treinamento para extrair suas características, como cores, bordas ou texturas, como pode ser visto na Figura 6.

Figura 6 – Conjunto de núcleos.




Fonte: Krohn (2020).

A saída gerada por este processo de convolução consiste em um mapa que indica todas as localizações dentro da imagem onde foi detectada a característica visual relevante.

É por isso que frequentemente é denominado como “**mapa de características**”, como pode ser visto na Figura 7.

Figura 7 – Diferentes estágios de processamento em uma camada convolucional.




Fonte: Kelleher (2019).

Camadas de não linearidade são aplicadas para aprender características sofisticadas da entrada e adicionar complexidade ou profundidade à rede. A maioria dos dados do mundo real são não lineares e não podem ser treinados apenas com funções lineares (Arif; Rahim, 2024).

O “**pooling**” reduz o tamanho espacial da representação, com o objetivo de agrupar ou extrair as características importantes da saída de uma camada convolucional (Arif; Rahim, 2024), o esquema é mostrado na Figura 8.


Figura 8 – Esquemático dos métodos de agrupamento Max, médio e soma.



Fonte: Arif e Rahim (2024).

Após a convolução, as **Camadas totalmente conectadas**, são semelhantes à rede neural artificial regular e contêm neurônios que estão conectados a todos os neurônios da camada anterior, o esquema é mostrado na Figura 9.

Figura 9 – Camadas totalmente conectadas.



Fonte: Arif e Rahim (2024).

Resumindo, uma rede convolucional para análise de imagens funciona de maneira muito semelhante à forma como o cérebro processa informações visuais. A *CNN* é composta por camadas convolucionais que detectam características como bordas, texturas e cores.

Convolução: Inicialmente, a imagem é dividida em grades de *pixels* para então aplicar a convolução, que é a aplicação de filtros à imagem de entrada para detectar características simples, como bordas. Esse filtro desliza sobre a imagem e calcula o produto escalar entre os valores do filtro e os valores da imagem. Isso resulta em um mapa de características que destaca a presença das características detectadas ao longo da imagem.

Função de ativação: Após a convolução, é aplicada uma função de ativação (função não linear) para que a *CNN* aprenda a representar características mais complexas.

Agrupamento (*Pooling*): Em seguida, é aplicada a camada de agrupamento para reduzir o tamanho do mapa de características.

Camadas completamente conectadas: Por fim, as camadas completamente conectadas são ligadas para combinar as características extraídas de forma mais abstrata e realizar a classificação final.


3.3 MODELOS DE REDES NEURAIS CONVOLUCIONAIS

3.3.1 ResNet50

A *Microsoft Research* desenvolveu a *CNN ResNet*, que venceu o desafio *ILSVRC* 2015. A *ResNet* ampliou o *design* padrão das redes neurais convolucionais ao incorporar

conexões de atalho. Essas conexões permitem que a saída de uma camada na rede seja alimentada diretamente para uma camada que pode estar significativamente mais profunda na rede (Kelleher, 2019). Isso torna o uso de recursos mais eficiente, além de reduzir o problema do desaparecimento do gradiente (He *et al.*, 2016). *ResNet50* é uma variação da *ResNet* original, porém utiliza 50 camadas de profundidade (Matlab, 2024d), o esquema é mostrado na Figura 10.

Figura 10 – Arquitetura da *ResNet50*.



Fonte: Ali *et al.* (2021).


3.3.2 VGG19

VGGNet é uma rede neural criada pelo *Visual Geometry Group* da Universidade de *Oxford*. A largura dos filtros começa com 64 e é aumentada por um fator de 2 após cada camada de agrupamento (Balas; Mishra; Kumar, 2021). Entre as principais características está o fato de ser uma rede com uma arquitetura simples, que utiliza filtros e convoluções pequenos de 3x3, além do uso de 5 camadas de *maxpooling* (Simonyan; Zisserman, 2014). Para a versão *VGG19*, foram adicionadas 3 camadas convolucionais a mais do que a versão *VGG16* (Boesch, 2024). *VGG19* é uma rede neural convolucional com 201 camadas de profundidade (Matlab, 2024f), o esquema é mostrado na Figura 11.

3.3.4 Xception

Apresentado por François Chollet em 2017. O nome *Xception* é inspirado em “*Extreme Inception*”. O interessante do *Xception* é como ele lida com as convoluções. Segundo o estudo, o *Xception* propõe uma arquitetura de redes neurais convolucionais baseada inteiramente em camadas de convolução separável em profundidade. Ele sugere que o mapeamento de correlações entre canais e correlações espaciais nos mapas de características das redes neurais convolucionais pode ser totalmente desacoplado (Chollet, 2017). *Xception* possui 71 camadas de profundidade (Matlab, 2024g), o esquema é mostrado na Figura 13.

Figura 13 – Arquitetura da *Xception*.



Fonte: Chollet (2017).

3.3.5 DenseNet201

DenseNet201 é um modelo de rede neural convolucional (CNN) desenvolvido pela equipe de pesquisa do Facebook AI em 2017, liderada por Gao Huang. *DenseNet201* propõe uma rede neural convolucional densamente conectada, onde cada camada recebe como entrada as características produzidas por todas as camadas anteriores no modelo, mitigando assim o problema do desaparecimento do gradiente. Isso promove o fluxo de informações e resulta em uma melhoria na eficiência dos parâmetros, já que eles são compartilhados entre várias camadas (Huang *et al.*, 2017). *DenseNet201* é uma rede neural convolucional com 201 camadas de profundidade (Matlab, 2024a), o esquema é mostrado na Figura 14.

Figura 14 – Arquitetura da *DenseNet201*.

Layers	Output Size	DenseNet-121	DenseNet-169	DenseNet-201	DenseNet-264
Convolution	112×112	7×7 conv, stride 2			
Pooling	56×56	3×3 max pool, stride 2			
Dense Block (1)	56×56	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$
Transition Layer (1)	56×56	1×1 conv			
	28×28	2×2 average pool, stride 2			
Dense Block (2)	28×28	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$
Transition Layer (2)	28×28	1×1 conv			
	14×14	2×2 average pool, stride 2			
Dense Block (3)	14×14	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 24$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 64$
Transition Layer (3)	14×14	1×1 conv			
	7×7	2×2 average pool, stride 2			
Dense Block (4)	7×7	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 16$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$
Classification Layer	1×1	7×7 global average pool			
		1000D fully-connected, softmax			

Fonte: Huang *et al.* (2017).

Abaixo está a Tabela 4 com o resumo dos modelos *CNN*

Tabela 4 – Resumo dos Modelos de *CNN*.

Modelo	Profundidade	Tamanho	Parâmetros *	Imagem(px)
ResNet50	50	96 MB	25.6	224x224
VGG19	19	535 MB	144	224x224
InceptionV3	48	89 MB	23.9	299x299
Xception	71	85 MB	22.9	299x299
DenseNet201	201	77 MB	20	224x224


* Parâmetros (Milhões)

Fonte: Adaptado de (Matlab, 2024c).

3.4 APRENDIZADO DE TRANSFERÊNCIA

Michelucci define a aprendizagem por transferência como: “A aprendizagem por transferência é uma técnica na qual um modelo treinado para resolver um problema específico é reutilizado para um novo desafio relacionado ao primeiro problema” (Michelucchi, 2019). A utilização da aprendizagem por transferência é adequada quando se trata de processar imagens, pois as características como as bordas permanecem relativamente constantes e são úteis em quase todas as categorias visuais (Kelleher, 2019), o esquema é mostrado na Figura 15.

Figura 15 – Aprendizagem por transferência.



Fonte: Matlab (2024e).

4 APRENDIZAGEM PROFUNDO APLICADO AO DIAG-NÓSTICO DE CÂNCER DE PULMÃO

4.1 COLETA DE DADOS

O conjunto de dados é proveniente do hospital de ensino de oncologia e do centro nacional de doenças de câncer no Iraque. Os dados foram coletados ao longo de 2019 durante 3 meses. Ele inclui 1097 imagens, classificadas em 3 categorias que são 561 “Maligno”, 120 “Benigno” e 416 “Normal”. O scanner utilizado é da marca Siemens, modelo SOMATOM. O protocolo de tomografia computadorizada inclui: 120 kV, espessura do corte de 1 mm, com uma largura de janela variando de 350 a 1200 HU (Unidades Hounsfield) e um centro de janela de 50 a 600 que foram utilizados para a leitura, com retenção de respiração em inspiração completa. As pessoas que participaram do estudo são da região central do país, incluindo funcionários públicos, criadores de gado e agricultores (Mahimkar, 2024).

O conjunto de dados foi carregado do *Google Drive* e está organizado em subpastas, onde cada subpasta representa uma classe de imagem. Em seguida, todas as subpastas foram percorridas para ler as imagens e suas etiquetas. Também foi construído um dataframe do *Pandas* para armazenar o caminho das imagens e suas etiquetas. Além disso, foi realizado um balanceamento do conjunto de dados e, em seguida, o conjunto de dados balanceado foi dividido em conjuntos de treinamento e teste.

Entre os estudos que utilizaram este conjunto de dados, têm-se “*Diagnosis of Lung Cancer Based on CT Scans Using CNN*”, onde é apresentado um modelo de inteligência artificial baseado em uma rede neural convolucional utilizando a arquitetura AlexNet. Para isso, foi utilizado um conjunto de dados de 110 tomografias computadorizadas de casos de câncer de pulmão classificados em três classes. Após o treinamento, o modelo alcançou uma precisão geral de 93,548%. As principais conclusões foram que o modelo de aprendizado obteve uma precisão de 93,548% na detecção e classificação do câncer de pulmão, além de valores de precisão, sensibilidade e especificidade de até 97,1015%, 95,714% e 95%, respectivamente (Al-Yasriy *et al.*, 2020).

Outro estudo foi o artigo “ExtRanFS: Um Sistema Automatizado de Detecção de Malignidade do Câncer de Pulmão Usando Seletor de Características Extremamente Aleatório”, que se concentra no desenvolvimento de um sistema automatizado de detecção de malignidade do câncer de pulmão utilizando aprendizado de transferência. O conjunto de dados IQ-OTH/NCCD foi utilizado para extrair características relevantes e classificar os tumores em benignos, malignos ou normais através de um classificador MLP. O sistema alcançou uma precisão de 99,09% na classificação de imagens de TC de pulmão. (Nitha; Vinod, 2023).

Após concluir o processo de balanceamento, procede-se à divisão das imagens em conjuntos de treinamento e teste. No conjunto de treinamento, foram alocadas um total de 800 imagens, distribuídas em 400 imagens classificadas como Maligno, 320 como Normal e 80 como Benigno. Por outro lado, no conjunto de teste, há um total de 200 imagens, compostas por 100 imagens classificadas como Maligno, 80 como Normal e 20 como Benigno.

A estratégia de balanceamento usada é a sobreamostragem, que consiste em selecionar aleatoriamente amostras de cada categoria até que o número desejado seja alcançado. Nesse caso, foram selecionadas 400 amostras da categoria “Maligno”, 320 da categoria “Normal” e 80 da categoria “Benigno”.


O motivo por trás desse equilíbrio é evitar que um conjunto de dados seja dominado por uma categoria específica, o que pode afetar a precisão do modelo. Ao equilibrar o conjunto de dados, garante-se que cada categoria tenha um peso semelhante no treinamento do modelo.

4.2 PRÉ-PROCESSAMENTO DE IMAGENS

Para o processamento de imagens neste estudo, foram realizadas a carga das imagens, o balanceamento, a divisão e a geração de dados.

Para poder pré-processar as imagens, o código desenvolvido foi executado na plataforma *Colaboratory*, também chamada de *Colab*. Também conhecido como *Colab* ou *Google Colab*, é um produto da *Google Research* que permite escrever e executar código *Python* no navegador. Ele é projetado para ser usado em projetos de aprendizado de máquina, análise de dados e educação. Em termos técnicos, é um serviço de notebooks *Jupyter* hospedado na nuvem e não requer instalação. Pode ser usado gratuitamente, bem como em sua versão paga. Para o projeto, foi utilizado de ambas as maneiras. A versão pro inclui 12 GB de RAM e 225 GB de armazenamento. Além disso, inclui acesso a 100 unidades de computação por mês e *GPUs* mais rápidas (Google, 2024b), o esquema é mostrado na Figura 16.

Figura 16 – Ambiente do Colaboratory.



Fonte: Elaborado pelo autor.

Durante a etapa de pré-processamento de imagens, foram realizadas 2 atividades principais para garantir que os dados de entrada estivessem em um formato adequado para treinamento posterior em modelos. A primeira foi o redimensionamento de imagens, pois as imagens originais podem ter tamanhos e resoluções diferentes, o que pode dificultar o processamento. Portanto, todas as imagens foram redimensionadas para um tamanho uniforme, utilizando uma dimensão específica predefinida, que neste caso foi de (224, 224) pixels. Em seguida, foi realizada a normalização das imagens para melhorar a convergência do modelo durante o treinamento. A normalização geralmente envolve a escala dos valores de pixels para que estejam em uma faixa específica, que neste caso foi entre [0, 1], dividindo cada valor de pixel por 255. Essas atividades foram realizadas usando a classe *ImageDataGenerator* do Keras.

4.3 TREINAMENTO DOS MODELOS

Para o treinamento dos modelos, foram selecionados 5 modelos de redes neurais convolucionais pré-treinadas: *ResNet50*, *VGG19*, *InceptionV3*, *Xception* e *DenseNet201*. Esses modelos já foram previamente treinados com o conjunto de dados ImageNet. Foi construída uma arquitetura de rede neural específica para cada modelo, utilizando camadas predefinidas e compiladas usando o otimizador Adam e a função de perda de entropia cruzada categórica. Além disso, foram incluídos parâmetros de avaliação para monitorar o desempenho do modelo durante o treinamento. Durante o treinamento, o modelo ajustou os pesos de suas camadas internas para minimizar a função de perda nos dados de treinamento. Isso foi realizado durante o número de épocas configurado para cada cenário.

Devido à comparação entre diferentes modelos, otimizá-los individualmente resulta muito custoso em termos de recursos. Por isso, optou-se por otimizar os modelos de forma geral, visando melhorar o desempenho do algoritmo, de maneira empírica. Para isso, entre os parâmetros acessíveis em nível geral, estão a taxa de aprendizado, o número de exemplos de treinamento utilizados em uma iteração e as épocas. Apesar da escolha empírica dos parâmetros, eles também são mencionados no capítulo 8 do livro de *Deep Learning* (Goodfellow; Bengio; Courville, 2016).

4.4 AVALIAÇÃO DOS MODELOS

Durante a fase de avaliação dos modelos, após o treinamento, eles foram usados para prever as etiquetas de classe correspondentes no conjunto de dados de teste. Para isso, o modelo foi alimentado com as imagens do conjunto de teste, obtendo as previsões de classe correspondentes. Posteriormente, com as previsões do modelo e as etiquetas verdadeiras do conjunto de teste, o “accuracy” foi calculado para medir o desempenho dos modelos. Além disso, foram geradas as curvas ROC (Receiver Operating Characteristic) para cada modelo, bem como as matrizes de confusão. A visualização das matrizes permitiu identificar os erros na classificação e avaliar o desempenho do modelo para cada classe.

A curva ROC é um gráfico bidimensional que tem no eixo X a taxa de falsos positivos (FP) e no eixo Y a taxa de verdadeiros positivos (TP). A área sob a curva ROC (AUC) é a tradução da curva ROC em um número (Belciug, 2020).

Considerando o objetivo de encontrar o modelo com melhor desempenho na detecção de câncer de pulmão, surge uma disjunção. Por um lado, busca-se minimizar os falsos positivos para evitar gastos e custos desnecessários. Por outro lado, busca-se minimizar os falsos negativos para que mais pessoas possam receber um diagnóstico correto o mais cedo possível, maximizando assim suas chances de sobrevivência. Idealmente, aspira-se a alcançar ambos os objetivos, mas neste caso, a prioridade é minimizar os falsos negativos.


Segundo Burkov (2019), a matriz de confusão é uma tabela que resume o quão bem-sucedido o modelo de classificação é ao prever exemplos pertencentes a várias classes. Um eixo da matriz de confusão é o rótulo que o modelo previu, e o outro eixo é o rótulo real, o esquema é mostrado na Figura 17.

- Accuracy: É dada pelo número de exemplos classificados corretamente dividido pelo número total de exemplos classificados. Equação 1.

$$\text{Accuracy} = \frac{V P + V N}{V P + V N + F P + F N} \quad (1)$$

- Precisão: É a proporção de previsões positivas corretas para o número total de

Figura 17 – Matriz de confusão.



Fonte: Belciug (2020).

previsões positivas. Equação 2.

$$\text{Precisão} = \frac{V P}{V P + F P} \quad (2)$$

- Especificidade: É a proporção de verdadeiros negativos que são corretamente identificados pelo classificador. Equação 3.

$$\text{Especificidade} = \frac{V N}{V N + F P} \quad (3)$$

- Sensibilidade: É a proporção de previsões positivas corretas para o número total de exemplos positivos no conjunto de teste, O gráfico da matriz de confusão é mostrado na figura 18. Equação 4.

$$\text{Sensibilidade(Recall)} = \frac{V P}{V P + F N} \quad (4)$$

- *F1-score*: É calculado como a média harmônica da precisão e da recuperação. Equação 5.

$$F1\text{-score} = \frac{2(\text{Precisão})(\text{Sensibilidade})}{\text{Precisão} + \text{Sensibilidade}} \quad (5)$$

Segundo Belciug (2020) quando você tiver VP - Verdadeiro positivo, significa que o classificador previu corretamente a classe positiva. FP - Falso positivo, é quando um indivíduo obtém um resultado positivo quando deveria ter recebido um resultado negativo. FN - Falso negativo é o conceito oposto, onde um indivíduo recebe um resultado negativo em um exame médico quando deveria ter recebido um resultado positivo. VN - Verdadeiro negativo, significa que o classificador previu corretamente a classe negativa.

4.5 ANÁLISE DOS RESULTADOS

Nesta fase, foram analisadas as métricas de acurácia e a área sob a curva ROC (ROC-AUC) para comparar o desempenho dos modelos nos diferentes experimentos. Isso permitiu identificar quais modelos alcançaram os melhores resultados. As curvas ROC foram interpretadas para fornecer informações sobre a capacidade de discriminação do modelo. Além disso, as matrizes de confusão foram analisadas para avaliar o desempenho do modelo na classificação de cada classe em comparação com as etiquetas. O desempenho de cada modelo sob os diferentes cenários foi organizado em na Tabela 24 e Tabela 25.

5 RESULTADOS

Nesta fase inicial, procederá-se com a definição de alguns parâmetros fundamentais. O "*batch_size*" corresponde à quantidade de exemplos utilizados em uma iteração, o parâmetro "*epoch*" representa um ciclo completo percorrido durante o treinamento, e o "*learning_rate*" denota o tamanho dos passos tomados durante a otimização do modelo. É importante ressaltar que, para o gráfico da curva ROC, foi utilizada a curva ROC micro-averaged, com o objetivo de avaliar o desempenho geral do modelo sem priorizar nenhuma classe sobre as outras. A Tabela 5 mostra uma tabela com os parâmetros usados em cada cenário.

Tabela 5 – Tabela de cenários com seus respectivos parâmetros.

Cenário	Epoca	Tamanho	taxa de aprendizado
1	10	32	0,001
2	10	32	0,01
3	10	32	0,0001
4	20	64	0,001
5	20	64	0,0001
6	5	32	0,001
7	20	16	0,001
8	20	16	0,0001

Fonte: Elaborado pelo autor.

5.1 EXPERIMENTO 1

No total, serão desenvolvidos 8 experimentos, começando com um com parâmetros padrão e depois modificando-o para ver o desempenho dos modelos.


Para o experimento 1, os parâmetros são mostrados na Tabela 6.

Tabela 6 – Parâmetros usados no experimento 1.


Parâmetro	Valor
Número de exemplos de treinamento utilizados em uma iteração:	32
Epocas:	10
Taxa de aprendizado:	0,001

Fonte: Elaborado pelo autor.

No contexto deste modelo *ResNet50*, observa-se a presença de 20 falsos negativos na categoria de tumores benignos. Em relação aos tumores malignos, registram-se 100 verdadeiros positivos e 100 falsos positivos. Da mesma forma, para a categoria de estado normal, identificam-se 80 falsos negativos. O índice ROC associado é de 0,47


Figura 18 – Matriz de Confusão - *ResNet50*.

Fonte: Elaboração do próprio autor.


Figura 19 – Curva ROC - *ResNet50*.

Fonte: Elaboração do próprio autor.

No que diz respeito ao modelo *VGG19*, observam-se resultados comparáveis ao modelo anterior, com uma leve melhoria no índice ROC, atingindo 0,63.

Figura 20 – Matriz de Confusão - *VGG19*.


Fonte: Elaboração do próprio autor.

Figura 21 – Curva ROC - *VGG19*.

Fonte: Elaboração do próprio autor.


Neste contexto, o modelo *DenseNet201* apresenta resultados significativos na detecção de tumores malignos, com um total de 96 verdadeiros positivos, 4 falsos negativos e 1 falso positivo. No que diz respeito a amostras normais, identificado 1 falso negativo, 22 falsos positivos e 79 classificações corretas. Além disso, observa-se um valor de área sob a curva AUC de 0,97.

Figura 22 – Matriz de Confusão - *DenseNet201*.



Fonte: Elaboração do próprio autor.


Figura 23 – Curva ROC - *DenseNet201*.



Fonte: Elaboração do próprio autor.


No contexto deste modelo *InceptionV3*, observa-se a presença de 20 falsos negativos na categoria de tumores benignos. Em relação aos tumores malignos, registram-se 100 verdadeiros positivos e 100 falsos positivos. Da mesma forma, para a categoria de estado normal, identificam-se 80 falsos negativos. Além disso, calcula-se um valor de área sob a curva AUC de 0,76.

Figura 24 – Matriz de Confusão - *InceptionV3*.



Fonte: Elaboração do próprio autor.

Figura 25 – Curva ROC - *InceptionV3*.




Fonte: Elaboração do próprio autor.

No contexto do modelo *Xception*, evidencia-se um desempenho destacado na detecção de tumores benignos, com 19 verdadeiros positivos, 5 falsos positivos e 1 falso


negativo. Da mesma forma, alcança a identificação de 100% dos tumores malignos, enquanto para as amostras normais registram-se 5 falsos negativos, 1 falso positivo e 75 classificações corretas. Além disso, observa-se um valor de área sob a curva AUC de aproximadamente 1.

Figura 26 – Matriz de Confusão - Xception.



Fonte: Elaboração do próprio autor.

Figura 27 – Curva ROC - Xception.



Fonte: Elaboração do próprio autor.

5.2 EXPERIMENTO 2


Neste segundo cenário, o learning rate é modificado, para o experimento 2, os parâmetros são mostrados na Tabela 7.

Tabela 7 – Parâmetros usados no experimento 2.

Parâmetro	Valor
Número de exemplos de treinamento utilizados em uma iteração:	32 épocas:
10 taxa de aprendizado:	0,01
Fonte: Elaborado pelo autor.	


Neste contexto, o modelo *ResNet50* apresenta os seguintes resultados: no caso de amostras normais, detecta corretamente 72 casos, enquanto classifica 8 falsos negativos e 109 falsos positivos. Em relação aos tumores benignos, identifica 20 falsos negativos. No que diz respeito aos tumores malignos, consegue classificar corretamente 9 casos, mas classifica 91 como normais e 10 falsos positivos. Além disso, observa-se um valor de área sob a curva AUC de 0,65.

Figura 28 – Matriz de Confusão - *ResNet50*.



Fonte: Elaboração do próprio autor.


Figura 29 – Curva ROC - *ResNet50*.



Fonte: Elaboração do próprio autor.


No contexto deste modelo *VGG19*, observa-se a presença de 20 falsos negativos na categoria de tumores benignos. Em relação aos tumores malignos, registram-se 100 verdadeiros positivos e 100 falsos positivos. Da mesma forma, para a categoria de estado normal, identificam-se 80 falsos negativos. Observa-se um valor de área sob a curva AUC de 0,7.

Figura 30 – Matriz de Confusão - *VGG19*.



Fonte: Elaboração do próprio autor.


Figura 31 – Curva ROC - *VGG19*.



Fonte: Elaboração do próprio autor.


O modelo *DenseNet201* apresenta um comportamento semelhante ao modelo anterior, com um valor de área sob a curva AUC de 0,7.

Figura 32 – Matriz de Confusão - *DenseNet201*.



Fonte: Elaboração do próprio autor.


Figura 33 – Curva ROC - *DenseNet201*.



Fonte: Elaboração do próprio autor.


No caso do modelo *InceptionV3* neste cenário, observa-se que, para os tumores benignos, são registrados 20 falsos negativos. Em relação aos tumores malignos, identificam-se 56 verdadeiros positivos, 44 falsos negativos e 54 falsos positivos. No que concerne às amostras normais, detectam-se 44 falsos negativos, 54 falsos positivos e 36 verdadeiros positivos. O valor da área sob a curva *AUC* é de 0,61.

Figura 34 – Matriz de Confusão - *InceptionV3*.




Fonte: Elaboração do próprio autor.

Figura 35 – Curva ROC - *InceptionV3*.




Fonte: Elaboração do próprio autor.

Conforme observado neste cenário, para o modelo *Xception*, no caso dos tumores benignos, foram registrados 20 falsos negativos; para os tumores malignos, foram identificados 100 verdadeiros positivos e 84 falsos positivos; e para os casos normais, houve 66 falsos negativos e 2 falsos positivos. A curva *AUC* resultante foi de 0,66.

Figura 36 – Matriz de Confusão - *Xception*.

Fonte: Elaboração do próprio autor.

Figura 37 – Curva ROC - *Xception*.

Fonte: Elaboração do próprio autor.

5.3 EXPERIMENTO 3

Neste cenário, procederá-se a modificar o taxa de aprendizado para 0,0001. Para o experimento 3, os parâmetros são mostrados na Tabela 8.


Tabela 8 – Parâmetros usados no experimento 3.

Parâmetro	Valor
Número de exemplos de treinamento utilizados em uma iteração:	32
Epocas:	10
Taxa de aprendizado:	0,0001

Fonte: Elaborado pelo autor.


Conforme observado neste cenário, para o modelo *ResNet50*, no caso dos tumores benignos, foram registrados 20 falsos negativos; para os tumores malignos, foram identifi- cados 100 verdadeiros positivos e 100 falsos positivos; e para os casos normais, houve 80 falsos negativos. O valor da área sob a curva *AUC* é de 0,68.

Figura 38 – Matriz de Confusão - *ResNet50*.




Fonte: Elaboração do próprio autor.

Figura 39 – Curva ROC - *ResNet50*.




Fonte: Elaboração do próprio autor.

Neste cenário, o modelo *VGG19* no caso dos tumores benignos, foram registrados 1 verdadeiro positivo e 19 falsos negativos; para os tumores malignos, foram identificados 100 verdadeiros positivos; e para os casos normais, houve 79 verdadeiros positivos, 1 falso negativo e 19 falsos positivos. Além disso, observa-se um valor da área sob a curva AUC de 0,99.



Fonte: Elaboração do próprio autor.


Figura 41 – Curva ROC - *VGG19*.



Fonte: Elaboração do próprio autor.


O modelo *DenseNet201* apresenta 8 verdadeiros positivos, e 12 falsos negativos para os tumores benignos. Para os tumores malignos, foram identificados 100 verdadeiros positivos, 10 falsos positivos. Para o estado normal registra 73 verdadeiros positivos, 7 falsos negativos e 9 falsos positivos. Além disso, destaca-se um valor elevado da área sob a curva AUC de 0,99.

Figura 42 – Matriz de Confusão - *DenseNet201*.



Fonte: Elaboração do próprio autor.


Figura 43 – Curva ROC - *DenseNet201*.



Fonte: Elaboração do próprio autor.


Neste cenário, o modelo *InceptionV3* no caso dos tumores benignos, foram registrados 19 falsos negativos e 1 verdadeiro positivo; para os tumores malignos, foram identificados 100 verdadeiros positivos e 74 falsos positivos; e para os casos normais, houve 57 falsos negativos, 2 falsos positivos e 23 verdadeiros positivos. Além disso, observa-se um valor da área sob a curva *AUC* de 0,88.

Figura 44 – Matriz de Confusão - *InceptionV3*.



Fonte: Elaboração do próprio autor.

Figura 45 – Curva ROC - *InceptionV3*.



Fonte: Elaboração do próprio autor.

Neste cenário, o modelo *Xception* no caso dos tumores benignos, foram registrados 17 falsos negativos; para os tumores malignos, foram identificados 100 verdadeiros positivos; e para os casos normais foram identificados 80 verdadeiros positivos e 17 falsos positivos. Igualmente, destaca-se um valor elevado da área sob a curva *AUC* de 0,99.

Figura 46 – Matriz de Confusão - Xception.





Figura 47 – Curva ROC - Xception.



5.4 EXPERIMENTO 4

Nesse cenário, o tamanho será modificado do lote para 64 e o parâmetro épocas para 20. Para o experimento 4, os parâmetros são mostrados na Tabela 9.


Tabela 9 – Parâmetros usados no experimento 4.

Parâmetro	Valor
Número de exemplos de treinamento utilizados em uma iteração:	64
Épocas:	20
Taxa de aprendizado:	0,001

Fonte: Elaborado pelo autor.


Neste cenário, o tamanho do lote (*batch_size*) foi modificado para 64 e o número de épocas (*epoch*) para 20 no modelo *ResNet50*. Não são observadas alterações na matriz de confusão em comparação com o *batch_size* de 32. Contudo, nota-se uma área sob a curva AUC mais elevada, que agora é de 0,62 em comparação com 0,47.

Figura 48 – Matriz de Confusão - *ResNet50*.



Fonte: Elaboração do próprio autor.

Figura 49 – Curva ROC - *ResNet50*.



Fonte: Elaboração do próprio autor.

No cenário da *VGG19*, observa-se a presença de 20 falsos negativos na categoria de tumores benignos. Em relação aos tumores malignos, registram-se 100 falsos negativos e 100 falsos positivos. Da mesma forma, para a categoria de estado normal, identificam-se 80 verdadeiros positivos e 120 falsos positivos. No entanto, observa-se um valor da área sob a curva *AUC* de 0,72.

Figura 50 – Matriz de Confusão - *VGG19*.






Figura 51 – Curva ROC - *VGG19*.



Fonte: Elaboração do próprio autor.


Para o caso do *DenseNet201*, observa-se que, para os tumores benignos, há 16 verdadeiros positivos, 4 falsos negativos e um falso positivo. Para os malignos, há 100 verdadeiros positivos e 5 falsos positivos. Para o estado normal, há 75 verdadeiros positivos, 5 falsos negativos e 3 falsos positivos com uma curva *AUC* de aproximadamente 1.

Figura 52 – Matriz de Confusão - *DenseNet201*.



Fonte: Elaboração do próprio autor.


Figura 53 – Curva ROC - *DenseNet201*.



Fonte: Elaboração do próprio autor.


Para o modelo *InceptionV3* neste cenário, para os tumores malignos, há 100 verdadeiros positivos. Nos casos benignos, obteve-se 14 verdadeiros positivos e 6 falsos negativos. Em relação aos casos normais, registraram-se 80 verdadeiros positivos e 6 falsos positivos e um *AUC* de aproximadamente 1.

Figura 54 – Matriz de Confusão - *InceptionV3*.




Fonte: Elaboração do próprio autor.

Figura 55 – Curva ROC - *InceptionV3*.




Fonte: Elaboração do próprio autor.

No caso do *Xception* neste cenário, observa-se que para os tumores malignos, são registrados 100 verdadeiros positivos e 3 falsos positivos. Em relação aos tumores benignos, são identificados 13 verdadeiros positivos, 2 falsos positivos e 7 falsos negativos. Para os casos normais, contabilizam-se 77 verdadeiros positivos, 3 falsos negativos e 5 falsos positivos. Obteve-se uma curva *AUC* de aproximadamente 1.

Figura 56 – Matriz de Confusão - *Xception*.

Fonte: Elaboração do próprio autor.

Figura 57 – Curva ROC - *Xception*.

Fonte: Elaboração do próprio autor.

5.5 EXPERIMENTO 5

Para o experimento 5, os parâmetros são mostrados na Tabela 10.:


Tabela 10 – Parâmetros usados no experimento 5.

Parâmetro	Valor
Número de exemplos de treinamento utilizados em uma iteração:	64
Epocas:	20
Taxa de aprendizado:	0,0001

Fonte: Elaborado pelo autor.


Conforme observado neste cenário, para o modelo *ResNet50*, no caso dos tumores benignos, foram registrados 20 falsos negativos; para os tumores malignos, foram identificados 100 verdadeiros positivos e 80 falsos positivos; e para os casos normais, houve 80 falsos negativos. O valor da área sob a curva *AUC* é de 0,6.

Figura 58 – Matriz de Confusão - *ResNet50*.



Fonte: Elaboração do próprio autor.


Figura 59 – Curva ROC - *ResNet50*.



Fonte: Elaboração do próprio autor.


No modelo *VGG19*, neste cenário, para os tumores malignos, foram identificados 100 verdadeiros positivos. Para os tumores benignos, observa-se 20 falsos negativos, enquanto para os casos normais obtêm-se 80 verdadeiros positivos e 20 falsos positivos. O valor de *AUC* é de 0,98.

Figura 60 – Matriz de Confusão - *VGG19*.



Fonte: Elaboração do próprio autor.


Figura 61 – Curva ROC - *VGG19*.



Fonte: Elaboração do próprio autor.


Neste cenário, para o modelo *DenseNet201*, para os tumores malignos, foram identificados 100 verdadeiros positivos e 35 falsos positivos. No caso dos tumores benignos, são detectados corretamente 6 e 14 falsos negativos. Em relação aos casos normais, são classificados 55 verdadeiros positivos, 25 falsos negativos e 4 falsos positivos. Registra-se um valor de *AUC* de 0,95.

Figura 62 – Matriz de Confusão - *DenseNet201*.



Fonte: Elaboração do próprio autor.


Figura 63 – Curva ROC - *DenseNet201*.



Fonte: Elaboração do próprio autor.


No caso do modelo *InceptionV3*, neste cenário, para os tumores malignos, foram identificados 100 verdadeiros positivos e 37 falsos positivos. Na categoria de tumores benignos, consegue identificar 1 verdadeiro positivo e 19 falsos negativos. Em relação aos casos normais, detecta 56 verdadeiros positivos, 6 falsos positivos e 24 falsos negativos. O índice *AUC* associado é de 0,93.

Figura 64 – Matriz de Confusão - *InceptionV3*.



Fonte: Elaboração do próprio autor.


Figura 65 – Curva ROC - *InceptionV3*.



Fonte: Elaboração do próprio autor.


No caso do *Xception* neste cenário, observa-se que para os tumores malignos, são registrados 100 verdadeiros positivos e 11 falsos positivos. Em relação aos tumores benignos, são identificados 4 verdadeiros positivos e 16 falsos negativos. Para os casos normais, contabilizam-se 72 verdadeiros positivos, 8 falsos negativos e 13 falsos positivos. Obteve-se uma curva *AUC* de 0,98.

Figura 66 – Matriz de Confusão - Xception.



Fonte: Elaboração do próprio autor.

Figura 67 – Curva ROC - Xception.



Fonte: Elaboração do próprio autor.

5.6 EXPERIMENTO 6

Para o experimento 6, os parâmetros são mostrados na Tabela 11.:

Tabela 11 – Parâmetros usados no experimento 6.

Parâmetro	Valor
Número de exemplos de treinamento utilizados em uma iteração:	32
Epocas:	5
Taxa de aprendizado:	0,001

Fonte: Elaborado pelo autor.

Neste cenário, para o modelo *ResNet50*, a alteração no tamanho do lote para 32 e no número de épocas para 5 não afeta os resultados da matriz de confusão em relação ao cenário anterior. No entanto, teve um leve impacto positivo na curva *AUC*, que agora é de 0,62, em comparação com o valor anterior de 0,6.

Figura 68 – Matriz de Confusão - *ResNet50*.





Figura 69 – Curva ROC - *ResNet50*.



Fonte: Elaboração do próprio autor.

Neste cenário, o modelo *VGG19*, observa-se que em relação aos tumores benignos, são identificados 20 falsos negativos, para os tumores malignos, são registrados 100 verdadeiros positivos e 100 falsos positivos. Para os casos normais, contabilizam-se 80 falsos positivos. Além disso, o valor de *AUC* é de 0,78.

Figura 70 – Matriz de Confusão - *VGG19*.






Figura 71 – Curva ROC - *VGG19*.



Fonte: Elaboração do próprio autor.


No modelo *DenseNet201*, observa-se que para os tumores malignos, são registrados 100 falsos negativos. Em relação aos tumores benignos, são identificados 20 falsos negativos. Para os casos normais, contabilizam-se 80 verdadeiros positivos e 120 falsos positivos. O valor de *AUC* é de 0,69.

Figura 72 – Matriz de Confusão - *DenseNet201*.



Fonte: Elaboração do próprio autor.


Figura 73 – Curva ROC - *DenseNet201*.



Fonte: Elaboração do próprio autor.


No modelo *InceptionV3*, na detecção dos casos benignos, foram registrados 20 falsos negativos. Em relação aos casos normais, classificou incorretamente 34 falsos negativos, 1 falso positivo e 46 verdadeiros positivos. Para os tumores malignos, detectou corretamente 95, 5 falsos negativos e 53 falsos positivos. O valor de *AUC* é de 0,85.

Figura 74 – Matriz de Confusão - *InceptionV3*.





Fonte: Elaboração do próprio autor.

Figura 75 – Curva ROC - *InceptionV3*.



Fonte: Elaboração do próprio autor.

Para o modelo *Xception*, no caso de tumores benignos, foram registrados 6 verdadeiros positivos, 14 falsos negativos e 4 falsos positivos. Em relação aos tumores malignos, 96 foram detectados corretamente, com 4 falsos negativos. Para casos normais, um falso negativo foi identificado, 79 foram classificados corretamente e 15 falsos positivos. O valor de *AUC* é alto, sendo de 0,98.

Figura 76 – Matriz de Confusão - *Xception*.Figura 77 – Curva ROC - *Xception*.

5.7 EXPERIMENTO 7

Para o experimento 7, os parâmetros são mostrados na Tabela 12.


Tabela 12 – Parâmetros usados no experimento 7.

Parâmetro	Valor
Número de exemplos de treinamento utilizados em uma iteração:	16
Epocas:	20
Taxa de aprendizado:	0,001

Fonte: Elaborado pelo autor.


Para este novo cenário, o modelo *ResNet50* apresenta os seguintes resultados: para o caso de tumores benignos, registra 4 verdadeiros positivos, 21 falsos positivos e 16 falsos negativos. Em relação aos tumores malignos, são identificados 20 verdadeiros positivos e 80 falsos negativos. Por outro lado, para casos normais detecta 80 verdadeiros positivos e 75 falsos positivos. O valor do *AUC* é de 0,75.

Figura 78 – Matriz de Confusão - *ResNet50*.



Fonte: Elaboração do próprio autor.


Figura 79 – Curva ROC - *ResNet50*.



Fonte: Elaboração do próprio autor.


No contexto deste modelo *VGG19*, observa-se a presença de 20 falsos negativos na categoria de tumores benignos. Em relação aos tumores malignos, registram-se 100 verdadeiros positivos e 100 falsos positivos. Da mesma forma, para a categoria de estado normal, identificam-se 80 falsos negativos. Observa-se um valor de área sob a curva AUC de 0,74.

Figura 80 – Matriz de Confusão - *VGG19*.



Fonte: Elaboração do próprio autor.


Figura 81 – Curva ROC - *VGG19*.



Fonte: Elaboração do próprio autor.


Para o modelo *DenseNet201*, os casos benignos observa-se a presença de 20 verdadeiros positivos e 94 falsos positivos. No entanto, são registrados 100 falsos negativos para os tumores malignos. 4 falsos negativos, 6 falsos positivos para o estado normal, enquanto 76 são classificados corretamente. O valor de AUC é de 0,66.

Figura 82 – Matriz de Confusão - *DenseNet201*.



Fonte: Elaboração do próprio autor.

Figura 83 – Curva ROC - *DenseNet201*.




Fonte: Elaboração do próprio autor.

Para o modelo *InceptionV3*, são detectados 100 verdadeiros positivos para casos malignos. Para os benignos, são registrados 16 verdadeiros positivos, 4 falsos positivos e 4 falsos negativos. Em relação ao estado normal, 4 falsos positivos, 4 falsos negativos e 76 casos são classificados corretamente. Além disso, é obtido um *AUC* de aproximadamente


1.

Figura 84 – Matriz de Confusão - *InceptionV3*.




Fonte: Elaboração do próprio autor.

Figura 85 – Curva ROC - *InceptionV3*.




Fonte: Elaboração do próprio autor.

No caso do *Xception* neste cenário, observa-se que para os tumores malignos, são registrados 100 verdadeiros positivos e 30 falsos positivos. Em relação aos tumores benignos, são identificados 18 verdadeiros positivos, 42 falsos positivos e 2 falsos negativos. Para os casos normais, contabilizam-se 10 verdadeiros positivos e 70 falsos negativos. O valor de *AUC* é de 0,89.

Figura 86 – Matriz de Confusão - *Xception*.

Fonte: Elaboração do próprio autor.

Figura 87 – Curva ROC - *Xception*.

Fonte: Elaboração do próprio autor.

5.8 EXPERIMENTO 8

Para o experimento 8, os parâmetros são mostrados na Tabela 13.:


Tabela 13 – Parâmetros usados no experimento 8.

Parâmetro	Valor
Número de exemplos de treinamento utilizados em uma iteração:	16
Epocas:	20
Taxa de aprendizado:	0,0001

Fonte: Elaborado pelo autor.


Para este novo cenário, o modelo *ResNet50* apresenta os seguintes resultados: para o caso de tumores benignos, registra 20 falsos negativos. Em relação aos tumores malignos, são identificados 100 verdadeiros positivos. Por outro lado, para casos normais detecta 80 verdadeiros positivos e 20 falsos positivos. O valor do *AUC* é de 0,97.

Figura 88 – Matriz de Confusão - *ResNet50*.



Fonte: Elaboração do próprio autor.


Figura 89 – Curva ROC - *ResNet50*.



Fonte: Elaboração do próprio autor.


No contexto deste modelo *VGG19*, observa-se a presença de 3 verdadeiros positivos e 17 falsos negativos na categoria de tumores benignos. Em relação aos tumores malignos, registram-se 100 verdadeiros positivos e 1 falsos positivos. Da mesma forma, para a categoria de estado normal, identificam-se 79 verdadeiros positivos, 1 falso negativo e 17 falsos positivos. Observa-se um valor de área sob a curva *AUC* de 0,99.

Figura 90 – Matriz de Confusão - *VGG19*.



Fonte: Elaboração do próprio autor.


Figura 91 – Curva ROC - *VGG19*.



Fonte: Elaboração do próprio autor.


Para o modelo *DenseNet201*, os casos benignos observa-se a presença de 18 verdadeiros positivos, 4 falsos positivos e 2 falsos negativos. No entanto, são registrados 100 verdadeiros negativos para os tumores malignos. 4 falsos negativos e 2 falsos positivos para o estado normal, enquanto 76 são classificados corretamente. O valor de *AUC* é de aproximadamente 1.

Figura 92 – Matriz de Confusão - *DenseNet201*.



Fonte: Elaboração do próprio autor.


Figura 93 – Curva ROC - *DenseNet201*.



Fonte: Elaboração do próprio autor.


Para o modelo *InceptionV3*, são detectados 100 verdadeiros positivos para casos malignos. Para os benignos, são registrados 18 verdadeiros positivos e 2 falsos negativos. Em relação ao estado normal, 2 falsos positivos e 76 casos são classificados corretamente. Além disso, é obtido um *AUC* de aproximadamente 1.

Figura 94 – Matriz de Confusão - *InceptionV3*.



Fonte: Elaboração do próprio autor.


Figura 95 – Curva ROC - *InceptionV3*.



Fonte: Elaboração do próprio autor.


No caso do *Xception* neste cenário, observa-se que para os tumores malignos, são registrados 100 verdadeiros positivos. Em relação aos tumores benignos, são identificados 19 verdadeiros positivos, 4 falsos positivos e 1 falso negativo. Para os casos normais, contabilizam-se 76 verdadeiros positivos 4 falsos negativos e 1 falso positivo. O valor de *AUC* é de aproximadamente 1.

Figura 96 – Matriz de Confusão - Xception.



Fonte: Elaboração do próprio autor.

Figura 97 – Curva ROC - Xception.



Fonte: Elaboração do próprio autor.

6 DISCUSSÃO

Foram aplicados os 5 modelos de redes convolucionais sob diferentes condições com o objetivo de avaliar seu desempenho. Utilizou-se tanto a matriz de confusão quanto o gráfico ROC para medir a confiabilidade dos resultados.

Para o modelo *ResNet50*, o cenário 8 foi onde ele mostrou seu melhor desempenho com um valor de 0,933. Seu ponto mais baixo foi observado no cenário 2. Nos demais cenários, ele manteve uma eficiência constante de 0,667. Os principais fatores para a diminuição foram o *batch_size*=16 e também o *learning_rate*=0,0001. A Tabela 14 e Tabela 15 são apresentadas com os detalhes dos resultados.

Tabela 14 – Resultados para o Modelo *ResNet50*.

Modelo	Exp. 1	Exp. 2	Exp. 3	Exp. 4
<i>ResNet50</i>	0,667	0,603	0,667	0,667

Fonte: Elaborado pelo autor.

Tabela 15 – Resultados para o Modelo *ResNet50*.

Modelo	Exp. 5	Exp. 6	Exp. 7	Exp. 8
<i>ResNet50</i>	0,667	0,667	0,680	0,933

Fonte: Elaborado pelo autor.

Para o modelo *VGG19*, a pontuação mais alta também é observada no cenário 8, mas também demonstra alto desempenho nos cenários 3 e 5. O cenário com a pontuação mais baixa é o 4. Nos demais cenários, apresenta uma eficácia de 0,667. A Tabela 16 e Tabela 17 são apresentadas com os detalhes dos resultados..

Tabela 16 – Resultados para o Modelo *VGG19*.

Modelo	Exp. 1	Exp. 2	Exp. 3	Exp. 4
<i>VGG19</i>	0,667	0,667	0,933	0,600

Fonte: Elaborado pelo autor.

Tabela 17 – Resultados para o Modelo *VGG19*.

Modelo	Exp. 5	Exp. 6	Exp. 7	Exp. 8
<i>VGG19</i>	0,933	0,667	0,667	0,940

Fonte: Elaborado pelo autor.

No modelo *DenseNet201*, são apresentados altos resultados de 0,980 e 0,970, correspondentes aos experimentos 4 e 8. Seu desempenho mais baixo foi no experimento 6, com 0,600. A Tabela 18 e Tabela 19 são apresentados os detalhes dos resultados.

Tabela 18 – Resultados para o Modelo *DenseNet201*, experimento 1 ao experimento 4.

Modelo	Exp. 1	Exp. 2	Exp. 3	Exp. 4
<i>DenseNet201</i>	0,923	0,667	0,937	0,970

Fonte: Elaborado pelo autor.

Tabela 19 – Resultados para o Modelo *DenseNet201*, experimento 5 ao experimento 8.

Modelo	Exp. 5	Exp. 6	Exp. 7	Exp. 8
<i>DenseNet201</i>	0,870	0,600	0,653	0,980

Fonte: Elaborado pelo autor.

Para o modelo *InceptionV3*, são observados três cenários com uma pontuação alta nos experimentos 4, 7 e 8. O experimento 8 mostrou o melhor desempenho com 0,993. Por outro lado, o cenário 2 exibiu sua pontuação mais baixa com 0,640. A Tabela 20 e Tabela 21 são apresentados os detalhes dos resultados.

Tabela 20 – Resultados para o Modelo *InceptionV3*.

Modelo	Exp. 1	Exp. 2	Exp. 3	Exp. 4
<i>InceptionV3</i>	0,667	0,640	0,747	0,980

Fonte: Elaborado pelo autor.

Tabela 21 – Resultados para o Modelo *InceptionV3*.

Modelo	Exp. 5	Exp. 6	Exp. 7	Exp. 8
<i>InceptionV3</i>	0,857	0,803	0,973	0,993

Fonte: Elaborado pelo autor.

Para o modelo *Xception*, observa-se que, em sua maioria, apresenta altos desempenhos, sendo o máximo no cenário 8 e também alto no cenário 1. O cenário 2 representa seu ponto mais baixo. A Tabela 22 e Tabela 23 são apresentados os detalhes dos resultados.

Tabela 22 – Resultados para o Modelo *Xception*.

Modelo	Exp. 1	Exp. 2	Exp. 3	Exp. 4
<i>Xception</i>	0,980	0,713	0,943	0,967

Fonte: Elaborado pelo autor.

Tabela 23 – Resultados para o Modelo *Xception*.

Modelo	Exp. 5	Exp. 6	Exp. 7	Exp. 8
<i>Xception</i>	0,920	0,937	0,760	0,983

Fonte: Elaborado pelo autor.

Como pode ser observado, no cenário 8 foi onde todos os modelos apresentaram um desempenho superior a 90%. O cenário 2 teve desempenhos entre 0,6 e 0,8 para todos os modelos. O modelo *InceptionV3* no cenário 8 foi o que apresentou o mais alto desempenho com 0,993. O modelo *Xception* teve desempenhos acima de 0,9 em 6 cenários. A Tabela 24 e Tabela 25 mostra o consolidado com os diferentes cenários para a métrica de *accuracy*.

Tabela 24 – Resultados dos modelos com diferentes cenários.

Modelo	Exp. 1	Exp. 2	Exp. 3	Exp. 4
<i>ResNet50</i>	0,667	0,603	0,667	0,667
<i>VGG19</i>	0,667	0,667	0,933	0,600
<i>InceptionV3</i>	0,667	0,640	0,747	0,980
<i>Xception</i>	0,980	0,713	0,943	0,967
<i>DenseNet201</i>	0,923	0,667	0,937	0,970

Fonte: Elaborado pelo autor.

Tabela 25 – Resultados dos modelos com diferentes cenários.

Modelo	Exp. 5	Exp. 6	Exp. 7	Exp. 8
<i>ResNet50</i>	0,667	0,667	0,680	0,933
<i>VGG19</i>	0,933	0,667	0,667	0,940
<i>InceptionV3</i>	0,857	0,803	0,973	0,993
<i>Xception</i>	0,920	0,937	0,760	0,983
<i>DenseNet201</i>	0,870	0,600	0,653	0,980

Fonte: Elaborado pelo autor.

As informações são complementadas por outras métricas: sensibilidade, especificidade, precisão e *F1-score*. Para uma melhor visualização dos resultados, os cenários serão divididos em três grupos

Nesta primeira parte, serão visualizados os três primeiros cenários, pois compartilham parâmetros similares. Nestes cenários, apenas a taxa de aprendizado varia. A Tabela 26 mostra os parâmetros para os três primeiros cenários.

Tabela 26 – Tabela de cenários com seus respectivos parâmetros.

Cenário	Epoca	Tamanho	taxa de aprendizado
2	10	32	0,01
1	10	32	0,001
3	10	32	0,0001

Fonte: Elaborado pelo autor.

A Tabela 27 mostra os resultados das métricas de sensibilidade nos três primeiros cenários.

Tabela 27 – Resultados do modelo com a métrica de sensibilidade (*recall*).

Modelo	Exp. 2	Exp. 1	Exp. 3
<i>ResNet50</i>	0,405	0,500	0,500
<i>VGG19</i>	0,500	0,500	0,900
<i>InceptionV3</i>	0,460	0,500	0,620
<i>Xception</i>	0,570	0,970	0,915
<i>DenseNet201</i>	0,500	0,885	0,905

Fonte: Elaborado pelo autor.

A Tabela 28 mostra os resultados das métricas de precisão nos três primeiros cenários.

Tabela 28 – Resultados do modelo com a métrica de precisão.

Modelo	Exp. 2	Exp. 1	Exp. 3
<i>ResNet50</i>	0,405	0,500	0,500
<i>VGG19</i>	0,500	0,500	0,900
<i>InceptionV3</i>	0,460	0,500	0,620
<i>Xception</i>	0,570	0,970	0,915
<i>DenseNet201</i>	0,500	0,885	0,905

Fonte: Elaborado pelo autor.

A Tabela 29 mostra os resultados das métricas de especificidade nos três primeiros cenários.

Tabela 29 – Resultados do modelo com a métrica de especificidade.

Modelo	Exp. 2	Exp. 1	Exp. 3
<i>ResNet50</i>	0,776	0,750	0,750
<i>VGG19</i>	0,750	0,750	0,679
<i>InceptionV3</i>	0,760	0,750	0,723
<i>Xception</i>	0,734	0,670	0,677
<i>DenseNet201</i>	0,750	0,681	0,678

Fonte: Elaborado pelo autor.

A Tabela 30 mostra os resultados das métricas de especificidade nos três primeiros cenários.

Tabela 30 – Resultados do modelo com a métrica de *F1-score*.

Modelo	Exp. 2	Exp. 1	Exp. 3
<i>ResNet50</i>	0,405	0,500	0,500
<i>VGG19</i>	0,500	0,500	0,900
<i>InceptionV3</i>	0,460	0,500	0,620
<i>Xception</i>	0,570	0,970	0,915
<i>DenseNet201</i>	0,500	0,885	0,905

Fonte: Elaborado pelo autor.

Para esses três primeiros cenários, observa-se que, à medida que a taxa de aprendizado é otimizada, a sensibilidade melhora. Com isso em mente, outros cenários são explorados para avaliar seu comportamento. Além disso, o modelo inicial alcança bons resultados em mais de 90% e sua *F1-score* também é ótima.

Nesta segunda parte, serão apresentados os cenários 4, 5 e 6. Será revisado o comportamento das métricas. A Tabela 31 mostra os parâmetros para os cenários 4, 5 e 6.

Tabela 31 – Tabela de cenários com seus respectivos parâmetros.

Cenário	Epoca	Tamanho	taxa de aprendizado
4	20	64	0,001
5	20	64	0,0001
6	5	32	0,001

Fonte: Elaborado pelo autor.

A Tabela 32 mostra os resultados das métricas de sensibilidade para os cenários 4, 5 e 6.

Tabela 32 – Resultados do modelo com a métrica de sensibilidade (*recall*).

Modelo	Exp. 4	Exp. 5	Exp. 6
<i>ResNet50</i>	0,500	0,500	0,500
<i>VGG19</i>	0,400	0,900	0,500
<i>InceptionV3</i>	0,970	0,785	0,705
<i>Xception</i>	0,950	0,880	0,905
<i>DenseNet201</i>	0,955	0,805	0,400

Fonte: Elaborado pelo autor.

A Tabela 33 mostra os resultados das métricas de precisão para os cenários 4, 5 e 6.

Tabela 33 – Resultados do modelo com a métrica de precisão.

Modelo	Exp. 4	Exp. 5	Exp. 6
<i>ResNet50</i>	0,500	0,500	0,500
<i>VGG19</i>	0,400	0,900	0,500
<i>InceptionV3</i>	0,970	0,785	0,705
<i>Xception</i>	0,950	0,880	0,905
<i>DenseNet201</i>	0,955	0,805	0,400

Fonte: Elaborado pelo autor.

A Tabela 34 mostra os resultados das métricas de especificidade para os cenários 4, 5 e 6.

Tabela 34 – Resultados do modelo com a métrica de especificidade.

Modelo	Exp. 4	Exp. 5	Exp. 6
<i>ResNet50</i>	0,750	0,750	0,750
<i>VGG19</i>	0,778	0,679	0,750
<i>InceptionV3</i>	0,670	0,695	0,707
<i>Xception</i>	0,672	0,681	0,678
<i>DenseNet201</i>	0,672	0,692	0,778

Fonte: Elaborado pelo autor.

A Tabela 35 mostra os resultados das métricas de *F1-score* para os cenários 4, 5 e 6.

Tabela 35 – Resultados do modelo com a métrica de *F1-score*.

Modelo	Exp. 4	Exp. 5	Exp. 6
<i>ResNet50</i>	0,500	0,500	0,500
<i>VGG19</i>	0,400	0,900	0,500
<i>InceptionV3</i>	0,970	0,785	0,705
<i>Xception</i>	0,950	0,880	0,905
<i>DenseNet201</i>	0,955	0,805	0,400

Fonte: Elaborado pelo autor.

Com esses 3 cenários, o modelo *Xception* alcançou uma sensibilidade e um *F1-score* acima de 90%, embora os dados com os outros modelos não se mostrem conclusivos.

Após observar os parâmetros dos primeiros 6 cenários, foram selecionados mais 2 que, de acordo com o que foi observado, deveriam nos fornecer os melhores resultados. A Tabela 36 mostra os resultados das métricas de sensibilidade para os cenários 7 e 8.

Tabela 36 – Tabela de cenários com seus respectivos parâmetros.

Cenário	Epoca	Tamanho	taxa de aprendizado
7	20	16	0,001
8	20	16	0,0001

Fonte: Elaborado pelo autor.

A Tabela 37 mostra os resultados das métricas de sensibilidade para os cenários 7 e 8.

Tabela 37 – Resultados do modelo com a métrica de sensibilidade (*recall*).

Modelo	Exp. 7	Exp. 8
<i>ResNet50</i>	0,520	0,900
<i>VGG19</i>	0,500	0,910
<i>InceptionV3</i>	0,960	0,990
<i>Xception</i>	0,640	0,975
<i>DenseNet201</i>	0,480	0,970

Fonte: Elaborado pelo autor.

A Tabela 38 mostra os resultados das métricas de precisão para os cenários 7 e 8.

Tabela 38 – Resultados do modelo com a métrica de precisão.

Modelo	Exp. 7	Exp. 8
<i>ResNet50</i>	0,520	0,900
<i>VGG19</i>	0,500	0,910
<i>InceptionV3</i>	0,960	0,990
<i>Xception</i>	0,640	0,975
<i>DenseNet201</i>	0,480	0,970

Fonte: Elaborado pelo autor.

A Tabela 39 mostra os resultados das métricas de especificidade para os cenários 7 e 8.

Tabela 39 – Resultados do modelo com a métrica de especificidade.

Modelo	Exp. 7	Exp. 8
<i>ResNet50</i>	0,745	0,679
<i>VGG19</i>	0,750	0,677
<i>InceptionV3</i>	0,671	0,668
<i>Xception</i>	0,719	0,669
<i>DenseNet201</i>	0,755	0,670

Fonte: Elaborado pelo autor.

A Tabela 40 mostra os resultados das métricas de *F1-score* para os cenários 7 e 8.

Tabela 40 – Resultados do modelo com a métrica de *F1-score*.

Modelo	Exp. 7	Exp. 8
<i>ResNet50</i>	0,520	0,900
<i>VGG19</i>	0,500	0,910
<i>InceptionV3</i>	0,960	0,990
<i>Xception</i>	0,640	0,975
<i>DenseNet201</i>	0,480	0,970

Fonte: Elaborado pelo autor.

A sensibilidade é superior a 90% para todos os modelos e o mesmo se aplica ao *F1-score*, indicando que os parâmetros são ideais para os modelos avaliados.

7 CONCLUSÕES

O câncer de pulmão apresenta uma alta taxa de mortalidade na América Latina. Um diagnóstico precoce aumentaria significativamente a probabilidade de sucesso no tratamento do paciente. Infelizmente, na América Latina, muitas pessoas não têm acesso aos sistemas de saúde públicos ou privados, seja devido ao custo ou à falta de infraestrutura adequada. Este trabalho apresenta uma comparação de cinco modelos diferentes de aprendizado profundo (*Deep Learning*) que podem ser usados para o diagnóstico de câncer de pulmão por meio de imagens médicas. Esses modelos podem ser posteriormente utilizados em uma plataforma online, de modo que as pessoas ou profissionais médicos tenham acesso a consultar um diagnóstico a baixo custo ou gratuitamente.

O conjunto de dados utilizado corresponde a uma base de dados do Hospital Oncológico do Iraque disponível no *Kaggle*. Para este trabalho, foram disponibilizados 200 casos, dos quais 20 são tumores benignos, 100 são tumores malignos e 80 foram classificados como saudáveis.

Neste estudo, foram utilizados cinco modelos de redes convolucionais: *ResNet50*, *VGG19*, *DenseNet201*, *InceptionV3* e *Xception*, aplicados em diferentes cenários. Para cada cenário, cada modelo teve um comportamento diferente. Em uma visão macro, o modelo que obteve o melhor desempenho foi o *InceptionV3* no cenário 8. Os modelos que tiveram melhor desempenho ao revisar todos os cenários foram *Xception*, *InceptionV3* e *DenseNet201*, sendo que *Xception* foi ligeiramente superior em termos de *accuracy*, como teve uma porcentagem superior a 0,9 em 6 de 8 cenários. Por outro lado, a *ResNet50* teve os piores desempenhos em sete dos oito cenários avaliados. Para a métrica de sensibilidade, o melhor desempenho foi no cenário 8, com mais de 90%. Da mesma forma, o *F1-score* também foi superior a 90%.

Observou-se que a cada ajuste na taxa de aprendizado ou aumento nos ciclos de treinamento, uma maior precisão era alcançada, mas isso acarretava um aumento considerável na demanda por recursos computacionais.

TRABALHOS FUTUROS

Dentre os principais trabalhos futuros, podem ser sugeridos os seguintes:

1. Trabalhar com um conjunto de dados de alguma cidade do Brasil.
2. Trabalhar com um conjunto de dados com maior quantidade de casos.
3. Trabalhar com um conjunto de dados que contenha mais informações para possibilitar a segmentação.

4. Seria interessante contar com informações complementares dos pacientes, como idade e sexo.
5. Experimentar com outros modelos de *CNN*.
6. Colaborar com um especialista em câncer e encontrar maneiras de otimizar o diagnóstico.
7. Aplicar o conhecimento a outros tipos de câncer.
8. Implementar uma plataforma web de diagnóstico online.

REFERÊNCIAS

- ACS. **What is the câncer?:** AMERICAN CANCER SOCIETY - what is the difference between a benign and a malignant tumor? New York: [s. n.], 2024. Disponível em: <https://www.cancer.org/cancer/understanding-cancer/what-is-cancer.html>. Acesso em: 10 fev. 2024. Citado 2 vezes nas páginas 19 e 20.
- AGARWAL, A. Review of lung cancer detection and classification using deep learning. **Cyber Security and AI facilitators: challenges and Application**, Lefkosa, v. 1, n. 2, p. 7, 2023. Disponível em: <https://dergi.neu.edu.tr/index.php/aiit/article/view/800/353>. Acesso em: 10 fev. 2024. Citado na página 16.
- AIZENBERG, I. N.; AIZENBERG, N. N.; VANDEWALLE, J. **Redes Neurais ART e ARTMAP com Treinamento Continuado:** uma apresentação detalhada dos principais tipos de redes neurais do tipo art e artmap. Saarbrucken: Novas Edicoes Academicas, 2016. Citado na página 25.
- AL-SHABI, M.; SHAK, K.; TAN, M. Procan: Progressive growing channel attentive nonlocal network for lung nodule classification. **Pattern Recognition**, Amsterdam, v. 122, n. 1, p. 11, 2022. DOI: <https://doi.org/10.1016/j.patcog.2021.108309>. Citado na página 16.
- AL-YASRIY, H. F. *et al.* Diagnosis of lung cancer based on ct scans using CNN. **IOP Materials Science and Engineering**, Thi-Qar, v. 928, p. 1–9, 2020. Disponível em <https://api.semanticscholar.org/CorpusID:229481010>. Citado na página 35.
- ALI, L. *et al.* Performance evaluation of deep cnn-based crack detection and localization techniques for concrete structures. **Sensors**, Basel, v. 21, n. 5, p. 1–22, 2021. DOI: <https://doi.org/10.3390/s21051688>. Citado na página 30.
- ARIF, T. M.; RAHIM, A. **Deep Learning for Engineers**. Boca Raton: CRC, 2024. Citado 3 vezes nas páginas 26, 28 e 29.
- BALAS, V. E.; MISHRA, B. K.; KUMAR, R. **Handbook of Deep Learning in Biomedical Engineering**. Cambridge: Academic, 2021. Citado na página 30.
- BANSAL, S. **Code:** Cnn architectures: Vgg, resnet, inception+ tk, in: Kaggle. São Francisco: [s. n.], 2018. Disponível em: <https://www.kaggle.com/code/shivamb/cnn-architectures-vgg-resnet-inception-tl>. Acesso em: 09 fev. 2024. Citado na página 31.
- BELCIUG, S. **Artificial intelligence in cancer:** diagnostic to tailored treatment. Cambridge: Academic, 2020. Citado 2 vezes nas páginas 38 e 39.
- BOESCH, G. **Deep Learning:** Vgg very deep convolutional networks (vggnet) – what you need to know, in: Viso suite. Schaffhausen: [s. n.], 2024. Disponível em: <https://viso.ai/deep-learning/vgg-very-deep-convolutional-networks/>. Data de acesso: 09 fev. 2024. Citado na página 30.

BRASIL. Ministério da Saúde. Instituto Nacional de Câncer - INCA. **Câncer de pulmão**: Brasília, DF, 2022. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/cancer/tipos/pulmao>. Acesso em: 03 maio 2024. Citado 2 vezes nas páginas 19 e 22.

BRASIL. Ministério da Saúde. Instituto Nacional de Câncer - INCA. **Câncer**. Brasília, 2023. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/cancer/o-que-e->. Acesso em: 09 fev. 2024. Citado na página 19.

BRASIL. Ministério da Saúde. Instituto Nacional de Câncer - INCA. **Câncer de pulmão**: dados. Ministério da saúde. instituto nacional de câncer (INCA). Brasília, DF, 2023. Disponível em: <https://www.gov.br/inca/pt-br/>. Acesso em: 09 fev. 2024. Citado na página 20.

BRASIL. Ministério da Saúde. Instituto Nacional de Câncer - INCA. **Câncer de pulmão**: números. Brasília, DF, 2023. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/cancer/numeros/>. Data de acesso: 09 de fevereiro de 2024. Citado na página 16.

BRASIL. Ministério da Saúde. Instituto Nacional de Câncer - INCA. **Cancer pulmon**. Brasília, DF, 2023. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/cancer/tipos/pulmao>. Data de acesso: 09 fev. 2024. Citado na página 16.

BRASIL. Ministério da Saúde. comissão nacional de incorporação de tecnologias (CONITEC). **Relatório para sociedade**: informações sobre recomendações de incorporação de medicamentos e outras tecnologias no SUS: Alectinibe: para o tratamento do câncer de pulmão de células não pequenas localmente avançado ou metastático cujos tumores expressam rearranjo no gene alk. Brasília, DF, 2023. Disponível em: https://www.gov.br/conitec/pt-br/midias/consultas/relatorios/2023/sociedade/20230725_resoc_415_alectinibe_cancer_de_pulmao.pdf. Acesso em: 09 fev. 2024. Citado na página 19.

BRASIL. Ministério da Saúde. Instituto Nacional de Câncer - INCA. **Grupo de câncer hereditário**. Brasília, DF, 2024. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/pesquisa/pesquisa-translacional-e-aplicacao-diagnostica/genetica-e-virologia-tumoral/grupo-de-cancer-hereditario>. Acesso em: 03 maio 2024. Citado na página 19.

BURKOV, A. **The hundred-page machine learning book**. Quebec: Andriy Burkov, 2019. v. 1. Citado na página 38.

BUSCHETTO, L. **Utilização de redes neurais convolucionais na detecção, segmentação e classificação de núcleos celulares para identificação de aneuploidia**. 2021. 78 f. Dissertação (Mestrado em Engenharia de Automação e Sistemas) — Universidade Federal de Santa Catarina, Florianópolis, 2021. Citado na página 16.

CHIU, H.-Y. *et al.* Artificial intelligence for early detection of chest nodules in x-ray images. **Biomedicine**, Basel, v. 10, n. 11, p. 15, 2022. Citado na página 17.

CHOLLET, F. Xception: deep learning with depthwise separable convolutions. In: IEEE CONGRESS ON EVOLUTIONARY COMPUTATION, 2017, Honolulu. **Proceedings** [...] Pistacaway: IEEE, 2017. p. 1800–1807. Disponível em: 10.1109/CVPR.2017.195. Acesso em: 09 fev. 2024. Citado na página 32.

CHOWDHARY, K. R. **Fundamentals of artificial intelligence**. New Delhi: Springer, 2020. Citado 3 vezes nas páginas 23, 24 e 26.

DENNIS, M. A. **Marvin Minsky: american scientist**. Chicago: [s. n.], 2024. Disponível em: <https://www.britannica.com/biography/Marvin-Lee-Minsky>. Enciclopedia Britannica, Data de acesso: 09 fev. 2024. Citado na página 23.

GARATE, B.; BECERA, P.; OSADA, J. **Epidemiología del cáncer en el seguro social de salud del Perú: un análisis descriptivo del período 2019 - 2022**. Lima: ESSALUD, 2023. Disponível em: <https://ietsi.essalud.gob.pe/wp-content/uploads/2023/10/RRI-09-2023.pdf>. Acesso em: 26 abr. 2024. Citado na página 21.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. Cambridge: MIT Press, 2016. Disponível em: <http://www.deeplearningbook.org>. Citado na página 38.

GOOGLE. **Advanced guide to inception v3**. Mountain View: [s. n.], 2024. Disponível em: <https://cloud.google.com/tpu/docs/inception-v3-advanced>. Acesso em: 09 fev. 2024. Citado na página 31.

GOOGLE. **Colaboratory**. Mountain View, 2024. Disponível em: <https://research.google.com/colaboratory/faq.html>. Acesso em: 10 fev. 2024. Citado na página 36.

HE, K. *et al.* Proceedings deep residual learning for image recognition. In: CONFERENCE - COMPUTER VISION AND PATTERN RECOGNITION 2016, 2016, Las Vegas. **Proceedings** [...] Piscataway: IEEE, 2016. p. 770–778. DOI: <https://doi.org/10.1109/CVPR.2016.90>. Citado na página 30.

HUANG, G. *et al.* Densely connected convolutional networks. **Proceedings Computer Vision and Pattern Recognition**, Honolulu, p. 4700–4708, 2017. DOI: <https://doi.org/10.48550/arXiv.1608.06993>. Citado 2 vezes nas páginas 32 e 33.

KELLEHER, J. D. **Deep learning**. Cambridge: The MIT Press, 2019. Citado 5 vezes nas páginas 24, 25, 28, 30 e 33.

KROHN, J. **Deep learning illustrated**. London: AddisonWesley, 2020. Citado 2 vezes nas páginas 26 e 27.

LAUDER, E. **AI Business: ray kurzweil predicts that the singularity will take place by 2045**. London: [s. n.], 2017. Disponível em: <https://aibusiness.com/responsible-ai/ray-kurzweil-predicts-that-the-singularity-will-take-place-by-2045>. Acesso em: 09 fev. 2024. Citado na página 23.

MAHIMKAR. **The IQ-OTH/NCCD lung cancer dataset**: Kaggle. 2024. Disponível em: <https://www.kaggle.com/datasets/hamdallak/the-iqothnccd-lung-cancer-dataset>. Data de acesso: 10 de fevereiro de 2024. Citado 3 vezes nas páginas 21, 22 e 35.

MATLAB. **DenseNet201**. [S. l.], 2024. Disponível em: <https://la.mathworks.com/help/deeplearning/ref/densenet201.html>. Acesso em: 09 fev. 2024. Citado na página 32.

MATLAB. **InceptionV3**. [S. l.], 2024. Disponível em: <https://la.mathworks.com/help/deeplearning/ref/inceptionv3.html>. Data de acesso: 09 de fevereiro de 2024. Citado na página 31.

MATLAB. **Redes neurales profundas preentrenadas**. [S. l.], 2024. Disponível em: <https://la.mathworks.com/help/deeplearning/ug/pretrained-convolutional-neural-networks.html>. Data de acesso: 09 fev. 2024. Citado na página 33.

MATLAB. **Resnet50**. [S. l.], 2024. Disponível em: <https://la.mathworks.com/help/deeplearning/ref/resnet50.html>. Data de acesso: 09 de fevereiro de 2024. Citado na página 30.

MATLAB. **Transfer learning**. [S. l.], 2024. Disponível em: <https://shorturl.at/vwCL3>. Acesso em: 10 fev. 2024. Citado na página 34.

MATLAB. **VGG19**. [S. l.], 2024. Disponível em: <https://la.mathworks.com/help/deeplearning/ref/vgg19.html>. Data de acesso: 09 fev. 2024. Citado na página 30.

MATLAB. **Xception**. [S. l.], 2024. Disponível em: <https://la.mathworks.com/help/deeplearning/ref/xception.html>. Data de acesso: 09 fev. 2024. Citado na página 32.

MC. **Diagnosis**: fenix: MAYO CLINIC. [S. l.], 2023. Disponível em: <https://www.mayoclinic.org/diseases-conditions/lung-cancer/diagnosis-treatment/drc-20374627>. Data de acesso: 09 de fevereiro de 2024. Citado 2 vezes nas páginas 21 e 22.

MCCARTHY, J. *et al.* A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. **AI magazine**, New Hampshire, v. 27, n. 4, p. 12–12, 2006. DOI: <https://doi.org/10.1609/aimag.v27i4.1904>. Citado na página 23.

MICHELUCCHI, U. **Advanced applied DL**. New York: Apress, 2019. Citado na página 33.

NATIONAL CANCER INSTITUTE. **Computed Tomography (CT) Scans and Cancer**. Bethesda, 2024. Disponível em: <https://www.cancer.gov/about-cancer/diagnosis-staging/ct-scans-fact-sheet>. Acesso em: 03 jan. 2024. Citado na página 22.

NITHA, V. R.; VINOD, C. S. S. Extranfs: um sistema automatizado de detecção de malignidade do câncer de pulmão usando seletor de características extremamente aleatório. **Diagnostic**, Basel, v. 13, n. 13, p. 23–63, 2023. DOI: <https://doi.org/10.3390/diagnostics13132206>. Citado na página 35.

ORGANIZACIÓN PANAMERICANA DE LA SALUD - OPS. **Déficit de 600 mil profissionais de saúde**: Washington, 2023. Disponível em: <https://www.paho.org/pt/noticias/27-5-2022-americas-tem-deficit-600-mil-profissionais-saude-afetando-acesso-saude-em-areas>. OPAS, Data de acesso: 09 de fevereiro de 2024. Citado na página 16.

ORGANIZACIÓN PANAMERICANA DE LA SALUD - OPS. **Tasa mortalidad**. Washington, 2023. Disponível em: <https://www.paho.org/es/temas/cancer>. OPAS, Acesso em: 09 fev. 2024. Citado na página 16.

ROTHMAN, D. **Artificial Intelligence By example**: acquire advanced ai, machine learning, and deep learning design skills. Birmingham: Packt Publishing, 2020. Citado 2 vezes nas páginas 26 e 27.

SOCIEDADE BRASILEIRA DE RADIOTERAPIA - SBRT. **Fila de espera por exames na capital**. 2023. Disponível em: https://sbradioterapia.com.br/wp-content/uploads/2024/01/Nota_Oficial_SBRT_01-2024.pdf. Acesso em: 09 fev. 2024. Citado na página 16.

SCHOFIELD, J. **John McCarthy obituary**: the guardian. Londres: [s. n.], 2011. Disponível em: <https://www.theguardian.com/technology/2011/oct/25/john-mccarthy>. Acesso em: 09 fev. 2024. Citado na página 23.

SIMON, H.; NEWELL, A.; SHAW, J. **History of information**: Newell: [s. n.], 1958. <https://www.historyofinformation.com/detail.php?id=742>. Acesso em: 09 fev. de 2024. Citado na página 23.

SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. In: COMPUTER VISION AND PATTERN RECOGNITION, 2014, San Diego. Proceedings [...] Oxford: Oxford University, 2014. p. 14. Disponível em: <http://dblp.uni-trier.de/db/conf/iclr/iclr2015.html#SimonyanZ14a>. Acesso em: 09 fev. de 2024. Citado na página 30.

SZEGEDY, C. *et al.* Rethinking the inception architecture for computer vision. In: CONFERENCE - COMPUTER VISION AND PATTERN RECOGNITION 2016, 2016, Las Vegas. **Proceedings** [...] New York: IEEE, 2016. p. 2818–2826. Citado na página 31.

TAULLI, T. **Artificial intelligence basics**. California: Apress, 2019. Citado na página 26.