



UNIVERSIDADE FEDERAL DO CEARÁ
CAMPUS DE QUIXADÁ
CURSO DE GRADUAÇÃO EM SISTEMAS DE INFORMAÇÃO

ANA KELY LOPES FERREIRA

DETECÇÃO DE CÂNCER DE MAMA EM IMAGENS HISTOPATOLÓGICAS
UTILIZANDO CNN COM TRANSFERÊNCIA DE CONHECIMENTO E
TRANSFERÊNCIA DE COR

QUIXADÁ

2021

ANA KELY LOPES FERREIRA

DETECÇÃO DE CÂNCER DE MAMA EM IMAGENS HISTOPATOLÓGICAS
UTILIZANDO CNN COM TRANSFERÊNCIA DE CONHECIMENTO E TRANSFERÊNCIA
DE COR

Trabalho de Conclusão de Curso apresentado ao
Curso de Graduação em Sistemas de Informação
do Campus de Quixadá da Universidade Federal
do Ceará, como requisito parcial à obtenção do
grau de bacharel em Sistemas de Informação.

Orientador: Prof. Dr. Críston Pereira de
Souza

QUIXADÁ

2021

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

F439d Ferreira, Ana Kely Lopes.

Detecção de câncer de mama em imagens histopatológicas utilizando CNN com transferência de conhecimento e transferência de cor / Ana Kely Lopes Ferreira. – 2022.
51 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Quixadá, Curso de Sistemas de Informação, Quixadá, 2022.

Orientação: Prof. Dr. Críston Pereira de Souza.

1. Neoplasias da Mama. 2. Visão computacional. 3. Transmissão do Conhecimento. 4.
Cor. I. Título.

CDD 005

ANA KELY LOPES FERREIRA

DETECÇÃO DE CÂNCER DE MAMA EM IMAGENS HISTOPATOLÓGICAS
UTILIZANDO CNN COM TRANSFERÊNCIA DE CONHECIMENTO E TRANSFERÊNCIA
DE COR

Trabalho de Conclusão de Curso apresentado ao
Curso de Graduação em Sistemas de Informação
do Campus de Quixadá da Universidade Federal
do Ceará, como requisito parcial à obtenção do
grau de bacharel em Sistemas de Informação.

Aprovada em: ____/____/____.

BANCA EXAMINADORA

Prof. Dr. Críston Pereira de Souza (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Regis Pires Magalhães
Universidade Federal do Ceará (UFC)

Prof. Dr. Paulo de Tarso Guerra Oliveira
Universidade Federal do Ceará (UFC)

A Deus, por me olhar como a menina dos Seus olhos. À minha mãe, por ser a minha fonte de força e amor. Ao meu pai, por todo o carinho e cuidado. Aos meus irmãos, por me amarem e me fazerem feliz. À minha avó Maria(in memoriam), que me amou bravamente.

AGRADECIMENTOS

Ao escrever essas linhas, a emoção toma conta de mim. Foram 4 longos e sofridos anos, que me provaram que Deus faz tudo perfeito e que todos os sonhos que temos no coração são louváveis, pois Ele permitiu que fossem plantados. Diante disso, eu não poderia deixar de agradecer a Ele, que me deu o dom da vida, saúde, sabedoria, forças e uma família que me ama e me apoia. Obrigada, Senhor, por ser tão grandioso na minha vida e me conceder a realização de tantas coisas.

Agradeço aos meus pais, Maria e Antonio Ivan, por serem a minha raiz de vida, de exemplo e de força. A nossa história é linda, pois é feita de muita luta e determinação. Em alguns momentos eu pensei em desistir, mas lembrei que fui criada para vencer. Em especial, agradeço à minha amada Mãe, por ter me ensinado a ser uma mulher forte e determinada, obrigada por ser meu maior exemplo de vida, por amar e cuidar de mim e dos meus irmãos. Eu te darei o mundo, Mãe. Porque a senhora merece.

Agradeço aos meus irmãos, Kaline e Jonatas, por me amarem e serem meus exemplos de vida. Obrigada por serem meus irmãos, eu sou feliz por tê-los em minha vida. Agradeço à minha avó Maria Lopes (*in memoriam*), que me amou bravamente e me ensinou a importância do amor puro e verdadeiro. A senhora já não se encontra presente fisicamente, mas permanece viva em meu coração. Esta conquista é nossa, minha Mizinha.

Agradeço aos meus amigos, Vitinho, Ivanilson, Evenilson, Aglailson, Vitória, Pedro, Bruno, Thierry, Jhon, Ronier, Victor, Junior Casemiro e Júnior Melo, amigos que conheci na faculdade e seguraram a minha mão nos momentos de alegria e tristezas. Agradeço ao meu time do VTEX Lab da UFC - Quixadá: Alyson, Rafael, George, Beatriz, Samuel, Gustavo, Andrine, Enyo e Ingrid. Obrigada por me ouvirem, por me aconselharem e por me ajudarem a se tornar uma estudante e profissional melhor.

Agradeço a todos os meus professores. Em especial, ao meu ex-tutor do PET-SI, Wladimir, por acreditar em mim e me incentivar a ser melhor. Agradeço ao meu orientador, prof. Críston, por confiar o seu precioso tempo na realização deste trabalho. Obrigada por acreditar na minha capacidade, na minha competência e na importância deste trabalho. A Educação muda a vida das pessoas, porque é feita por pessoas como você, que acreditam nos sonhos dos seus alunos. Agradeço a banca deste trabalho, em nome dos professores Regis Magalhães e Paulo de Tarso. Obrigada pela disponibilidade, pelas observações importantes e acreditarem neste trabalho.

Agradeço a minha prima, Emily Sabrina, por ser minha alegria. Por me ouvir falar sobre livros, séries e surtar comigo por Harry Potter. Por fim, não menos importante, agradeço ao presidente Luiz Inácio Lula da Silva, o nordestino, semi-analfabeto, ex-metalúrgico, sindicalista e revolucionário, que permitiu que milhares de brasileiros de origem humilde, assim como eu, pudessem ingressar na Universidade pública de qualidade. Acredito no governo que faça nossos sonhos florescerem, não no que acredita que a Universidade só causa gastos. Viva a Universidade, a Ciência e repúdio ao negacionismo.

“Só eu sei cada passo por mim dado nessa estrada esburacada que é a vida, passei coisas que até mesmo Deus duvida, fiquei triste, capiongo, aperreado, porém nunca me senti desmotivado, me agarrava sempre numa mão amiga, e de forças minha alma era munida pois do céu a voz de Deus dizia assim: – Suba o queixo, meta os pés, confie em mim, vá pra luta que eu cuido das feridas.”

(Bráulio Bessa)

RESUMO

O câncer de mama é uma doença caracterizada pela proliferação desenfreada de células que podem acarretar no surgimento de tumores próximos da região da mama. Nos últimos anos, o câncer de mama tem sido considerado o segundo tipo de câncer com mais ocorrências de casos a nível mundial e nacional, ressaltando a importância do diagnóstico precoce e preciso. Entretanto, o diagnóstico de câncer de mama tem enfrentado diversos desafios aos profissionais da saúde e especialistas, visto a dificuldade de análise de amostras de biópsias, por exemplo. Tendo isso em vista e considerando o avanço computacional das técnicas de visão computacional para reconhecimento de imagens, muitos pesquisadores e especialistas consideram que o uso de sistemas CAD (*Computer-Aided Diagnosis*) para o auxílio do diagnóstico de câncer de mama por meio do uso de técnicas de processamento de imagens e aprendizado de máquina podem contribuir positivamente no diagnóstico de câncer de mama junto aos especialistas. Dessa forma, este trabalho implementa três abordagens de CNN's de arquitetura VGG-16 utilizando as técnicas de transferência de conhecimento e transferência de cor, objetivando propor e avaliar uma solução para a detecção de câncer de mama em imagens histopatológicas de câncer utilizando CNN com transferência de conhecimento e transferência de cor.

Palavras-chave: Neoplasias da Mama. Visão computacional. Transmissão de conhecimento. Cor.

ABSTRACT

Breast cancer is a disease characterized by the unrestrained proliferation of cells that can lead to the appearance of tumors near the breast region. In recent years, breast cancer has been considered the second type of cancer with the most occurrences of cases worldwide and nationally, highlighting the importance of early and accurate diagnosis. However, the diagnosis of breast cancer has faced several challenges for health professionals and specialists, given the difficulty of analyzing biopsy samples, for example. With this in mind and considering the computational advance of computer vision techniques for image recognition, many researchers and specialists consider that the use of CAD systems (*Computer-Aided Diagnosis*) to aid in the diagnosis of breast cancer by through the use of image processing techniques and machine learning can positively contribute to the diagnosis of breast cancer with specialists. Thus, this work implements three approaches of CNN's of VGG-16 architecture using the techniques of knowledge transfer and color transfer, aiming to propose and evaluate a solution for the detection of breast cancer in histopathological images of cancer using CNN with knowledge transfer and color transfer.

Keywords: Breast neoplasms. Computer vision. Knowledge transmission. Color.

LISTA DE ILUSTRAÇÕES

| | |
|---|----|
| Figura 1 – Interligação entre neurônios de entrada e neurônios ocultos. | 19 |
| Figura 2 – Compartilhamento de pesos e parâmetros entre neurônios de uma CNN. . . | 19 |
| Figura 3 – Esquematização de uma CNN simples. | 20 |
| Figura 4 – Comparativo entre procedimentos tradicionais e transferência de conhecimento. | 22 |
| Figura 5 – Representação das etapas necessárias para a execução do presente trabalho. . | 30 |
| Figura 6 – Amostra de tumor maligno pertencente ao conjunto <i>BreakHis</i> | 32 |
| Figura 7 – Amostra pertencente à categoria MSS. | 33 |
| Figura 8 – Experimento com arquitetura ResNet50 | 38 |
| Figura 9 – Experimento com arquitetura VGG16 | 39 |
| Figura 10 – Acurácia e <i>loss</i> da CNN <i>BreakHis</i> baseline sem <i>dropout</i> e regularização . . | 40 |
| Figura 11 – Acurácia e <i>loss</i> da CNN <i>BreakHis</i> baseline com <i>dropout</i> e regularização . . | 40 |
| Figura 12 – Acurácia e <i>loss</i> da CNN <i>MSI vs MSS</i> sem <i>dropout</i> e regularização | 41 |
| Figura 13 – Acurácia e <i>loss</i> da CNN <i>MSI vs MSS</i> com <i>dropout</i> e regularização | 41 |
| Figura 14 – Acurácia de treino e validação sem <i>dropout</i> e regularização | 42 |
| Figura 15 – Acurácia de treino e validação com <i>dropout</i> e regularização | 42 |
| Figura 16 – Transferência de cor do conjunto <i>BreakHis</i> para o conjunto <i>MSI vs MSS</i> . . | 43 |
| Figura 17 – Acurácia e <i>loss</i> de treino e validação sem <i>dropout</i> e regularização | 43 |
| Figura 18 – Acurácia e <i>loss</i> de treino e validação com <i>dropout</i> e regularização | 43 |
| Figura 19 – Acurácia e <i>loss</i> de treino e validação CNN <i>BreakHis</i> com transferência de cor sem <i>dropout</i> e regularização | 44 |
| Figura 20 – Acurácia e <i>loss</i> de treino e validação CNN <i>BreakHis</i> com transferência de cor com <i>dropout</i> e regularização | 44 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 1 – Características do conjunto de dados <i>BreakHis</i> | 31 |
| Tabela 2 – Mapeamento das arquiteturas utilizadas nos trabalhos relacionados. | 33 |
| Tabela 3 – Comparativo dos resultados obtidos | 45 |

LISTA DE QUADROS

| | |
|---|----|
| Quadro 1 – Comparação entre os trabalhos relacionados e o proposto. | 29 |
|---|----|

SUMÁRIO

| | | |
|----------------|--|-----------|
| 1 | INTRODUÇÃO | 15 |
| 1.1 | Contribuições | 16 |
| <i>1.1.1</i> | <i>Objetivo Geral</i> | <i>16</i> |
| <i>1.1.2</i> | <i>Objetivos Específicos</i> | <i>16</i> |
| 2 | FUNDAMENTAÇÃO TEÓRICA | 17 |
| 2.1 | Aprendizado de Máquina | 17 |
| 2.2 | Aprendizado Profundo | 17 |
| 2.3 | Redes Neurais Convolucionais | 18 |
| <i>2.3.1</i> | <i>Campos Receptivos Locais</i> | <i>18</i> |
| <i>2.3.2</i> | <i>Compartilhamento de Parâmetros e Pesos na CNN</i> | <i>19</i> |
| <i>2.3.3</i> | <i>Amostragem</i> | <i>20</i> |
| 2.4 | Transferência de Conhecimento | 21 |
| 2.5 | Técnica de Transferência de Cor | 22 |
| 3 | TRABALHOS RELACIONADOS | 25 |
| 3.1 | <i>Classification of Breast Cancer Histology Images Using Multi-size and Discriminative Patches Based on Deep Learning (LI et al., 2019)</i> | <i>25</i> |
| 3.2 | <i>Breast Cancer Histopathology Image Classification Using an Ensemble of Deep Learning Models (HAMEED et al., 2020)</i> | <i>26</i> |
| 3.3 | <i>Double Transfer Learning for Breast Cancer Histopathologic Image Classification (MATOS et al., 2019)</i> | <i>26</i> |
| 3.4 | <i>Classification of Histopathological Images for Early Detection of Breast Cancer Using Deep Learning (SENAN et al., 2021)</i> | <i>27</i> |
| 3.5 | Análise Comparativa Entre os Trabalhos Relacionados e Este Trabalho | 28 |
| 4 | PROCEDIMENTOS METODOLÓGICOS | 30 |
| 4.1 | Coleta das Bases de Dados Experimentais | 31 |
| <i>4.1.1</i> | <i>Conjunto de Dados BreakHis</i> | <i>31</i> |
| <i>4.1.1.1</i> | <i>Características gerais</i> | <i>31</i> |
| <i>4.1.1.2</i> | <i>Desbalanceamento dos dados</i> | <i>32</i> |
| <i>4.1.2</i> | <i>Conjunto de Dados MSI vs MSS</i> | <i>32</i> |

| | | |
|-------|---|----|
| 4.2 | Identificação das Arquiteturas mais Utilizadas para Classificação de Imagens Histopatológicas | 33 |
| 4.3 | Implementação da CNN para Classificação do Conjunto BreakHis | 34 |
| 4.4 | Construção de um Classificador Baseado em Transferência de Conhecimento sem Transferência de Cor | 34 |
| 4.4.1 | <i>Implementação da CNN com Imagens do Conjunto MSI vs MSS</i> | 34 |
| 4.4.2 | <i>Aplicação de Transferência de Conhecimento a Partir do Modelo MSI vs MSS</i> | 35 |
| 4.5 | Aplicação da Técnica de Transferência de Cor do Conjunto <i>BreakHis</i> Para MSI vs MSS | 36 |
| 4.5.1 | <i>Aplicação de Transferência de Cor</i> | 36 |
| 4.6 | Construção de um Classificador Baseado em Transferência de Conhecimento com Transferência de Cor | 36 |
| 4.6.1 | <i>Implementação da CNN Baseada no Conjunto de Imagens com Transferência de Cor</i> | 36 |
| 4.6.2 | <i>Implementação de Transferência de Conhecimento</i> | 37 |
| 4.7 | Avaliação dos modelos preditivos | 37 |
| 4.8 | Análise Quantitativa dos Resultados Obtidos | 37 |
| 5 | RESULTADOS E DISCUSSÕES | 38 |
| 5.1 | Experimento para escolha da arquitetura CNN | 38 |
| 5.2 | Experimento para CNN de Classificação do Conjunto <i>BreakHis</i> | 39 |
| 5.3 | Experimento para Construção da CNN com Imagens do Conjunto <i>MSI vs MSS</i> | 40 |
| 5.4 | CNN <i>BreakHis</i> com Transferência de Conhecimento | 41 |
| 5.5 | Experimento de Transferência de Cor | 42 |
| 5.6 | CNN <i>MSI vs MSS</i> com Transferência de Conhecimento e de Cor | 43 |
| 5.7 | CNN <i>BreakHis</i> com Transferência de Conhecimento e de Cor | 44 |
| 5.8 | Comparativo dos resultados obtidos por meio de cada abordagem | 45 |
| 6 | CONCLUSÕES E TRABALHOS FUTUROS | 46 |
| | REFERÊNCIAS | 47 |

1 INTRODUÇÃO

Durante os últimos anos, o câncer de mama tem apresentado altas taxas de incidência, sendo considerado o segundo tipo de câncer com mais ocorrências de casos depois do câncer de pele melanoma (INCA, 2020). No ano de 2019, foram registrados cerca de 18.295 números de mortes, sendo 18.068 dessas mortes ocorridas em mulheres e 227 em homens. Além disso, segundo Instituto Nacional de Câncer (INCA), são estimados cerca de 66.280 novos casos para o ano de 2021. O câncer de mama pode resultar em mutações genéticas que causam o aumento do hormônio estrogênio, havendo a possibilidade de aparecimento de tumores também em regiões próximas à mama (OLIVEIRA *et al.*, 2020). Vale ressaltar, também, que alguns fatores genéticos, relacionados ao estilo de vida e ao ambiente, podem contribuir para a ocorrência desse tipo de câncer (SERVI, 2006).

Devido ao avanço exacerbado dos tumores de câncer de mama, vale salientar que o diagnóstico precoce tem uma alta relevância no controle da evolução da doença devido ao início antecipado do tratamento, que contribui para o aumento das chances de sobrevivência do paciente diagnosticado (SILVA *et al.*, 2020). Visto que o diagnóstico precoce é de suma importância, os principais procedimentos utilizados para diagnosticar essa doença são: a mamografia, exames clínicos, exames de sangue, raio-X, ultrassonografia, biópsia e outros (BERNARDES *et al.*, 2019). Dentre os procedimentos citados anteriormente, como destaque neste trabalho, temos a biópsia, que tem desempenhado um papel de extrema importância na detecção de câncer de mama (SILVA *et al.*, 2019), consistindo na retirada da amostra do tecido que contém o tumor suspeito para análise celular. Geralmente, esse tipo de procedimento é indicado para a confirmação da existência de câncer em casos de alterações na mama que possam aparentar nódulos.

Diante do avanço das técnicas de visão computacional com relação ao estudo, análise e processamento de características/recursos em imagens, diversos trabalhos têm desenvolvido pesquisas e projetos para a utilização dessas tecnologias no que trata-se da classificação desses tipos de imagens, a fim de contribuir com o trabalho de patologistas, uma vez que realiza o emprego de segmentação de cor e reconhecimento de padrões morfológicos por meio de análise dos pixels (BOASQUEVISQUE, 2020).

Dentre esses trabalhos, pode-se destacar: uma abordagem do treinamento da rede *ResNet50* com utilização do algoritmo *K-means* para clusterização dos dados, juntamente com transferência de cor e transferência de conhecimento, (LI *et al.*, 2019); treinamento de redes VGG

com uso de transferência de cor e transferência de conhecimento, por (HAMEED *et al.*, 2020); utilização de rede arquitetura *Inception-V3*, com transferência de cor e algoritmo SVM (MATOS *et al.*, 2019); treinamento de rede *AlexNet* com transferência de cor e transferência de conhecimento (SENAN *et al.*, 2021), ambos objetivando a classificação de imagens histopatológicas de câncer de mama.

Diante disso, este trabalho tem como base para sua realização os trabalhos citados acima, além de outros trabalhos que têm relação com classificação de imagens histopatológicas de câncer de mama por meio do uso de técnicas de transferência de cor e de conhecimento.

1.1 Contribuições

Nesta seção, serão apresentados os objetivos gerais e específicos do presente trabalho, respectivamente.

1.1.1 *Objetivo Geral*

Este trabalho tem como objetivo propor e avaliar uma solução para a detecção de câncer de mama em imagens histopatológicas de câncer de mama utilizando CNN com transferência de conhecimento e transferência de cor.

1.1.2 *Objetivos Específicos*

Como objetivos específicos, destaca-se:

1. Identificação de arquiteturas CNN's mais utilizadas na tarefa de classificação de imagens histopatológicas;
2. Construção de uma base de imagens obtida através da aplicação de transferência de cor da *BreakHis* para o conjunto de dados *MSI vs MSS* de (KATHER, 2019);
3. Treinamento de uma rede CNN para realizar a classificação de imagens de câncer com base no conjunto de dados *BreakHis*;
4. Treinamento de uma rede CNN com base no conjunto de dados *MSI vs MSS*, com o objetivo de utilizar as camadas iniciais para realizar transferência de conhecimento;
5. Avaliação da qualidade da classificação para as abordagens com ou sem transferência de conhecimento/transferência de cor.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção, são apresentados os conceitos essenciais para o desenvolvimento deste trabalho, bem como para sua compreensão. Na Seção 2.1, expõe-se o conceito de aprendizado de máquina e suas principais áreas de contribuição, na Seção 2.2 fala-se sobre o conceito de aprendizado profundo e suas principais aplicações, na Seção 2.3, é apresentado o algoritmo de rede neural convolucional utilizado neste trabalho, seguida pela Seção 2.4 que apresenta a técnica de transferência de conhecimento e a Seção 2.5 com a explicação sobre a técnica de transferência de cor.

2.1 Aprendizado de Máquina

Aprendizado de máquina (AM) é um campo da Inteligência Artificial (IA) que surgiu por volta da década de 60 e que está relacionada ao uso e ao desenvolvimento de técnicas computacionais sobre aprendizado, focada na construção de algoritmos capazes de aprender padrões de forma automática a partir de dados (MONARD; BARANAUSKAS, 2003). Devido a característica de reconhecimento de padrões, a área de aprendizado de máquina é considerada como uma área multidisciplinar, que envolve outras áreas de conhecimento, sendo uma delas, a estatística para análise e interpretação de dados (IZBICKI; SANTOS, 2020). Os algoritmos e técnicas de aprendizado de máquina têm apresentado diversas aplicações e têm sido utilizados em diversos campos, tais como: visão computacional, exames médicos engenharia espacial, finanças, entretenimento, biologia computacional e biomedicina (NAQA; MURPHY, 2015).

2.2 Aprendizado Profundo

Aprendizado profundo é uma área de aprendizado de máquina utilizada em tarefas mais complexas, por ser uma área caracterizada pela capacidade de extrair características em dados complexos (BOCHIE *et al.*, 2020). Devido à complexidade de algumas aplicações e desses dados, imagens por exemplo, os algoritmos de aprendizado de máquina precisaram ganhar mais capacidade computacional para processamento e ganho de conhecimento. Nesse contexto, os algoritmos de aprendizado profundo são caracterizados por apresentarem arquiteturas conhecidas como redes neurais, que permitem o controle da sua capacidade, como adicionar mais camadas de aprendizado e de generalização (MARQUES, 2016). Essas características possibilitam o reconhecimento de padrões nos dados durante o processo de treinamento, permitindo que

o conhecimento gerado seja generalizado ao longo da rede. Um exemplo de algoritmo de aprendizado profundo são as redes neurais convolucionais para reconhecimento de imagens, que são utilizadas neste trabalho.

2.3 Redes Neurais Convolucionais

Na década de 80, (FUKUSHIMA, 1988) propôs a primeira estrutura de uma Rede Neural Convolucional (CNN), objetivando a extração de características e informações em imagens por meio da utilização de conceitos de células e neurônios artificiais para detecção de padrões. Anos mais tarde, (LECUN *et al.*, 1998) acrescentaria o conceito de gradiente à estrutura de CNN para classificação de dígitos manuscritos. Tendo isso em vista e considerando o avanço da visão computacional com relação à captura de recursos por meio processamento de sinal em baixo nível (JÄHNE *et al.*, 1999), classificação e reconhecimento de objetos, além da sua interdisciplinaridade de uso em diversas áreas, tais como pesquisa médica e saúde (ULHAQ *et al.*, 2020), uma CNN é um algoritmo de visão computacional que tem possibilitado tarefas como reconhecimento facial, melhorias em diagnósticos médicos, veículos autônomos entre outras, (LI *et al.*, 2021).


Nesse contexto, o funcionamento e a estruturação de uma rede CNN baseia-se na conjuntura de três principais conceitos e ideias que acrescentam a esse tipo de rede mais robustez com relação à leitura, processamento e manipulação dos dados aos neurônios de entrada, sendo: campos receptivos locais, compartilhamento de parâmetros e pesos e amostragem (LECUN *et al.*, 1998), que serão explanados nas Subseções 2.3.1, 2.3.2 e 2.3.3, respectivamente.

2.3.1 Campos Receptivos Locais

Os dados de entrada de uma CNN são imagens que vêm em formato de matrizes altura x largura de acordo com suas dimensões. Cada pixel da imagem de entrada representa a intensidade da cor de sua matriz (SCURI, 1999), de acordo com a escala de cada canal RGB (*Red*, *Green* e *Blue*) ou com a escala de cinza contida na mesma. Além disso, vale ressaltar que a quantidade dos neurônios iniciais é determinada pelo total de pixels da matriz mencionada anteriormente. Para conectar os pixels de entrada à camada de neurônios ocultos, é realizada a tarefa de localizar pequenas regiões da imagem por meio dos chamados filtros de convolução (ANKILE *et al.*, 2020), que aprendem parâmetros ao longo da rede. Abaixo, na Figura 1, é

possível visualizar essa interligação.

Figura 1 – Interligação entre neurônios de entrada e neurônios ocultos.




Fonte: (ACADEMY, 2021)

Ademais, esses filtros de convolução deslizam pelos pixels da imagem de entrada, realizando o compartilhamento dos parâmetros entre os campos receptivos locais. Em análise, essa conexão entre os neurônios de entrada e os neurônios ocultos, possibilita o reconhecimento de linhas ou cantos combinadas pelas camadas subsequentes para reconhecimento de mais alto nível (LECUN *et al.*, 1998).

2.3.2 Compartilhamento de Parâmetros e Pesos na CNN

Para que seja possível detectar características e recursos das imagens de entrada a partir de diferentes e independentes ângulos, a rede CNN realiza a tarefa de compartilhamento e a memorização dos pesos, que são os parâmetros adaptáveis da rede (RAUBER, 2005). Essa etapa permite que os neurônios de uma camada compartilhem seus pesos, repassando-os para as camadas posteriores fornecendo dados ao longo da rede. Ademais, vale ressaltar que essa etapa de compartilhamento possibilita que a rede CNN aprenda de forma mais eficiente em comparação às Redes Neurais Artificiais (RNA's), quando os dados a serem aprendidos são imagens (REINHOLD, 2016). Na Figura 2 é possível observar a esquematização do compartilhamento de parâmetros e pesos entre os neurônios das camadas de uma CNN.

Figura 2 – Compartilhamento de pesos e parâmetros entre neurônios de uma CNN.



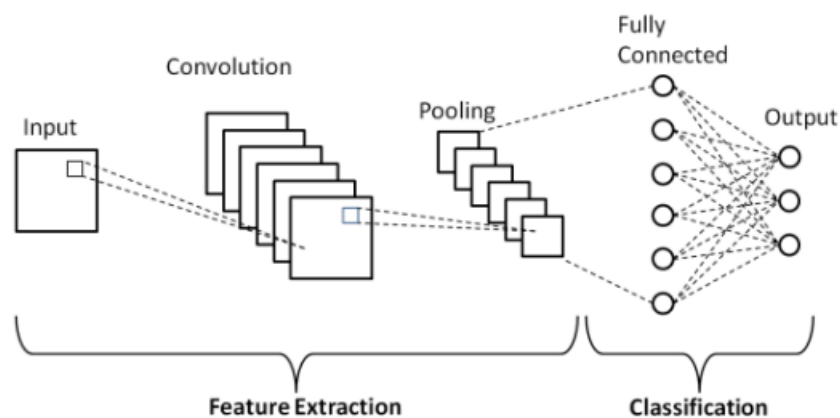
Fonte: (FARIA, 2018)

2.3.3 Amostragem

A etapa de amostragem, também conhecida como camada de *pooling*, objetiva criar uma nova forma de representação dos dados que seja mais compacta, realçando características e aspectos relevantes para o processo de aprendizado, desconsiderando informações irrelevantes identificadas durante a aplicação dos filtros de convolução. Dessa forma, a partir da compactação das características mais relevantes os dados tornam-se menos suscetíveis às transformações ou distorções de informações (BOUREAU *et al.*, 2010). Além disso, o processo de amostragem apresenta um importante papel no contexto de reduzir a perda de informação, na estabilização do treinamento da rede e atenuando a variação de gradientes na atualização dos pesos da CNN (WU *et al.*, 2017).

Em análise, a sequência de funcionamento de uma CNN inicia-se pela convolução das imagens, pelo compartilhamento dos pesos entre as camadas de convolução e pela etapa de amostragem que reduz o tamanho das imagens e realça informações identificadas como relevantes. Ademais, os recursos extraídos são combinados pela conexão total das camadas. Por fim, é realizada a tarefa de classificação de acordo com o(s) neurônio(s) de saída (PHUNG *et al.*, 2019). Abaixo, na Figura 3, é viável visualizar a estrutura de uma rede CNN básica, composta por uma camada de entrada, uma camada de convolução, uma camada de *pooling*, uma camada totalmente conectada e a camada de saída, sendo essas divididas nas categorias de extração e classificação de recursos (PHUNG *et al.*, 2019).

Figura 3 – Esquematização de uma CNN simples.



Fonte: (PHUNG *et al.*, 2019)

2.4 Transferência de Conhecimento

Ao longo dos anos, a técnica de transferência de conhecimento foi estudada e investigada, a fim de solucionar problemas existentes no contexto de aprendizado de máquina. Dessa forma, essa técnica é conhecida e chamada por diversos termos, tais como: aprendizagem por transferência, transferência indutiva, aprendizagem multitarefa, consolidação de conhecimento, aprendizagem sensível ao contexto, tendência indutiva baseada no conhecimento ou aprendizado incremental / cumulativo (THRUN; PRATT, 1998). Vale ressaltar que, desde meados dos anos 90, a utilização dessa técnica tem ganhado alta relevância.

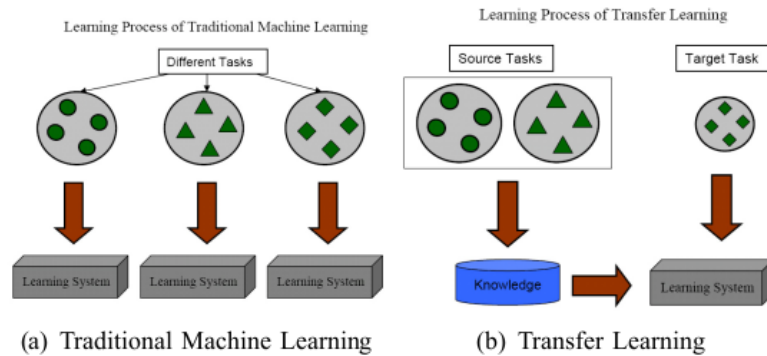
Em análise, alguns pesquisadores consideram que o treinamento do zero de alguns algoritmos de aprendizado de máquina e mineração de dados deve ocorrer quando se tem um mesmo contexto de recursos e uma distribuição relativamente equilibrada (PAN; YANG, 2009). Além disso, em alguns problemas e aplicações, o treinamento desses algoritmos necessitam de uma quantidade de dados relativamente grande, ultrapassando no caso do treinamento de redes profundas, por exemplo, cerca de milhões de amostras de dados (CRUZ *et al.*, 2020).

Ademais, uma pequena quantidade de dados para o treinamento desses algoritmos pode não ser suficiente, devido à necessidade de realizar ajustes na alta quantidade de parâmetros e pesos de uma rede. Nesse contexto, a transferência de conhecimento tem apresentado importância na atenuação do impacto da insuficiência dos dados (CRUZ *et al.*, 2020), uma vez que trata-se de uma técnica que consiste na utilização de uma rede pré-treinada com dados do mesmo contexto de uso ou em contextos diferentes, com o objetivo de completar o treinamento com base em dados específicos do problema em questão, contribuindo com a melhoria da classificação do modelo e aumentando a capacidade de reconhecimento (ROCHA *et al.*, 2019).

O processo de aprendizagem é diferente entre os procedimentos tradicionais e a transferência de conhecimento, uma vez que os métodos tradicionais geram conhecimento do zero a partir de cada tarefa e contexto, enquanto os de transferência geram aprendizado a partir de dados em contextos diferentes ou do mesmo contexto para uma classificação final com um conjunto de dados específico. Abaixo, na Figura 4 é representada a comparação descrita acima, onde na imagem (a) representa-se a esquematização do funcionamento do aprendizado de máquina tradicional, que gera conhecimentos diferentes de acordo com os dados que recebem. Ou seja, cada tarefa específica recebe dados específicos e gerará conhecimento a partir desses dados. Na segunda imagem (b), é representada a transferência de conhecimento, que recebe um conhecimento que foi gerado a partir de dados diferentes dos que deseja-se classificar, por

exemplo, fazendo o novo modelo e por fim gerar conhecimento a partir dessa combinação.

Figura 4 – Comparativo entre procedimentos tradicionais e transferência de conhecimento.



Fonte: (PAN; YANG, 2009)

2.5 Técnica de Transferência de Cor

Proposta por Reinhard *et al.* (2001), a técnica de transferência de cor entre imagens consiste em transferir cores características de uma imagem fonte para uma imagem destino, a fim de obter uma terceira imagem que contenha características morfológicas da imagem destino e as cores da imagem fonte. De forma geral, uma imagem composta por três canais, quando representada no espaço RGB, apresentará correlações entre os valores de pixels dos diferentes canais. A título de exemplo, no espaço RGB, os valores dos pixels, em sua maioria, conterá valores altos para o canal vermelho e verde, caso o canal azul também seja composto por valores grandes, (REINHARD *et al.*, 2001).

Dessa forma, a técnica de transferência de cor propõe, inicialmente, a manipulação de imagens que estão no espaço RGB, para o espaço $\alpha\beta$ baseado na proposta de (RUDERMAN *et al.*, 1998). A primeira etapa da conversão, consiste em transformar a imagem em RGB para o espaço de cores tristimulus XYZ, definido pela Comissão Internacional de Iluminação (CIE, com as iniciais do nome em francês), onde determina a intensidade dos estímulos fornecidos para olhos humano, com base nas três cores primárias (KERR, 2010).

No início dessa etapa, Reinhard *et al.* (2001) mapeia o branco das imagens por meio do diagrama de cromaticidade (CIE xy) para o branco do espaço RGB de forma mútua, a fim de corrigir valores inconsistentes de acordo com o monitor em que a imagem foi obtida, onde $x = X / (X + Y + Z) = 0,333$, $y = Y / (X + Y + Z) = 0,333$. Na Equação 2.1 é possível visualizar a

matriz de conversão do canal RGB para XYZ proposta por Reinhard *et al.* (2001):

$$\begin{pmatrix} X \\ Y \\ Z \end{pmatrix} = \begin{pmatrix} 0.5141 & 0.3239 & 0.1604 \\ 0.2651 & 0.6702 & 0.0641 \\ 0.0241 & 0.1228 & 0.8444 \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (2.1)$$

Uma vez que os dados estão no espaço XYZ independente ocorre a conversão de XYZ para o espaço LMS que simula a retina do olho humano, onde o (L) representa o comprimento de onda longo, geralmente cones seletivos da cor vermelha, o (M) refere-se aos cones de comprimento médio seletivos para a cor verde e o (S) são os cones de comprimento curto para a cor azul, (PAULA, 2006). Na equação abaixo, é possível observar essa conversão:

$$\begin{pmatrix} L \\ M \\ S \end{pmatrix} = \begin{pmatrix} 0.3897 & 0.6890 & -0.0787 \\ -0.2298 & 1.1834 & 0.0464 \\ 0.0000 & 0.0000 & 1.0000 \end{pmatrix} \begin{pmatrix} X \\ Y \\ Z \end{pmatrix} \quad (2.2)$$

Após essa etapa, para amenizar a alteração dos dados, uma transformação logarítmica é feita nos mesmos, proposta por (RUDERMAN *et al.*, 1998):

$$\mathbf{L} = \log L \quad \mathbf{M} = \log M \quad \mathbf{S} = \log S \quad (2.3)$$

Em seguida, para decorrelacionar os dados é utilizada a técnica estatística de Análise de Componentes Principais (PCA, da sigla em inglês), que transforma ortogonalmente um conjunto de observações de variáveis correlacionadas em um conjunto de valores lineares não correlacionados (KARAMIZADEH *et al.*, 2013). Após decorrelacionar esses eixos de dados, é realizada a conversão do espaço LMS decorrelacionado para o espaço $l\alpha\beta$:

$$\begin{pmatrix} l \\ \alpha \\ \beta \end{pmatrix} = \begin{pmatrix} \frac{1}{\sqrt{3}} & 0 & 0 \\ 0 & \frac{1}{\sqrt{6}} & 0 \\ 0 & 0 & \frac{1}{\sqrt{2}} \end{pmatrix} \begin{pmatrix} 1 & 1 & 1 \\ 1 & 1 & -2 \\ 1 & -1 & 0 \end{pmatrix} \begin{pmatrix} \mathbf{L} \\ \mathbf{M} \\ \mathbf{S} \end{pmatrix} \quad (2.4)$$

Sendo, o componente l a representação do canal acromático, o componente α a representação da diferença entre as cores amarelo e azul, e o canal β a representação da diferença entre as cores vermelho e verde. Após os dados estarem no espaço $l\alpha\beta$, (REINHARD *et al.*,

2001) propõe o cálculo da média e desvio padrão de cada um dos três eixos da imagem fonte e imagem destino, conforme mostrado nas Equações 2.5 e 2.6 abaixo. Na primeira Equação 2.5 é calculada subtração de cada canal do espaço $l\alpha\beta$ e suas respectivas médias. Na Equação 2.6 é calculado o desvio padrão de cada canal do espaço 2.6.

$$l^* = l - \langle l \rangle \quad \alpha^* = \alpha - \langle \alpha \rangle \quad \beta^* = \beta - \langle \beta \rangle \quad (2.5)$$

$$l' = \frac{\sigma_t^l}{\sigma_s^l} \quad \alpha' = \frac{\sigma_t^\alpha}{\sigma_s^\alpha} \quad \beta' = \frac{\sigma_t^\beta}{\sigma_s^\beta} \quad (2.6)$$

Após essa etapa, as médias da imagem fonte são adicionadas a cada eixo do espaço $l\alpha\beta$ e os dados são convertidos de volta para RGB através das operações inversas, como exponencial para o cálculo do logaritmo, e a multiplicação das matrizes inversas de LMS para XYZ e XYZ para RGB.

3 TRABALHOS RELACIONADOS

Nesta seção, serão apresentados trabalhos relacionados ao projeto proposto neste trabalho.

3.1 *Classification of Breast Cancer Histology Images Using Multi-size and Discriminative Patches Based on Deep Learning (LI et al., 2019)*

No trabalho de LI et al. (2019), os autores destacam como objetivo principal a proposta de um esquema abrangente e eficaz para a tarefa de multi-classificação de imagens de histologia da mama, a fim de melhorar o desempenho do diagnóstico assistido por computador. Nesse contexto, os mesmos utilizaram um conjunto de dados contendo imagens histopatológicas dividido em 4 classes de imagens normais, benignas, carcinoma *in situ* ou carcinoma invasivo, de acordo com o tipo de câncer ou normalidade, contido em cada imagem.

Dessa forma, na etapa de pré-processamento dos dados, os autores seguiram a técnica de transferência de cor, proposta por Reinhard *et al.* (2001), que transforma os canais RGB de cada imagem em um espaço de cores $l\alpha\beta$, a partir do cálculo da média e desvio padrão para cada canal no espaço $l\alpha\beta$, seguindo um conjunto de transformações lineares e combinando a distribuição de cores das imagens iniciais e finais, para converter os resultados de volta para RGB. Em seguida, os autores dividiram as amostras em *clusters*, por meio do uso do algoritmo de clusterização *K-means* buscando identificar características comuns entre os dados, utilizando uma CNN *ResNet50* para extração de recursos e como um classificador final, treinada a partir dessas amostras discriminativas com o objetivo de reforçar informações aprendidas por meio de um treino anterior.

Como resultados, os autores obtiveram a precisão de 95% no conjunto de teste inicial e 88,89% no conjunto de teste geral. A macro-F foi de 89,14%, calculada com base na média dos *F-scores* a partir das 4 categorias da classificação. Com relação às principais diferenças entre o trabalho de (LI *et al.*, 2019) e este trabalho, pode-se destacar o uso da tarefa de multi-classificação feita por (LI *et al.*, 2019), a utilização do algoritmo *K-means* para clusterização e no treinamento discriminativo, enquanto este trabalho realiza a tarefa de classificação binária de câncer ou não câncer, não utiliza clusterização de dados e nem a arquitetura *ResNet50*.

3.2 Breast Cancer Histopathology Image Classification Using an Ensemble of Deep Learning Models (HAMEED et al., 2020)

No trabalho de HAMEED et al. (2020), os autores objetivam a classificação correta da classe de carcinoma em um conjunto de dados pertencente ao Departamento de Patologia da Universidade Colsanitas Colombia, contendo cerca de 1690 imagens histopatológicas de câncer de mama, além de utilizar e realizar experimentos com arquiteturas VGG16 e VGG19 pré-treinadas para a tarefa de classificação.

Para pré-processar os dados, os autores utilizaram a técnica de normalização de cores proposta por Macenko *et al.* (2009), que converte as imagens em densidade óptica (OD) por meio de uma transformação logarítmica a fim de obter projeções bidimensionais com maior variância. Após esse processo, o resultado obtido por essas transformações é aplicado às imagens originais. Para a etapa de treinamento, 80% das imagens foram selecionadas e 20% para teste. Em seguida, os autores utilizaram validação cruzada subdividindo as imagens selecionadas para treinamento em 5 subconjuntos. Com o objetivo de expandir o conjunto de dados, o *ImageDataGenerator*, fornecido pelo Keras, foi utilizado. Por fim, os autores utilizaram a abordagem composta pelo conjunto das redes VGG16 e VGG19 para a classificação final.

Como resultados, os autores obtiveram 91,67% de precisão nos modelos VGG16 e um *F-score* de 91,63%. Com relação aos modelos VGG19, a precisão obtida foi de 90,35% e um *F-score* de 90,31%. A utilização do *ensemble* dessas duas arquiteturas apresentou uma precisão de 93,53% e um *F-score* de 95,29% com o modelo totalmente treinado e 95,29% de precisão com um *F-score* de 95,29% no ajuste fino. Com relação às diferenças entre o trabalho de Hameed *et al.* (2020) e este trabalho, é possível destacar que, enquanto o presente trabalho utiliza o conjunto de dados *BreakHis* para classificação final, o trabalho de Hameed *et al.* (2020) utiliza outro conjunto de dados. Além disso, Hameed *et al.* (2020) realiza experimentos em conjunto com duas arquiteturas diferentes e utiliza uma técnica para normalização dos dados diferente da que é utilizada neste trabalho.

3.3 Double Transfer Learning for Breast Cancer Histopathologic Image Classification (MATOS et al., 2019)

No trabalho de MATOS et al.(2019), os autores utilizaram transferência de conhecimento, a fim de melhorar a precisão da classificação de imagens histopatológicas de câncer

de mama. Dessa forma, inicialmente um algoritmo SVM foi treinado com relação ao conjunto de dados CRC, composto por imagens de características texturais do contexto histológico, a fim de identificar características relevantes para o treinamento. Após o processo de filtragem, foi utilizada uma rede *Inception-v3* pré-treinada no conjunto de dados *ImageNet*, sendo de um contexto diferente das imagens histopatológicas para a extração de características. Por fim, um segundo algoritmo SVM foi treinado para a tarefa de classificar imagens com tumores malignos ou benignos a partir do conjunto de dados *BreakHis*.

Como resultados, essa abordagem obteve a precisão de 89,9%, 91%, 89,7% e 86,7%, para os fatores de magnitude de 40X, 100X, 200X e 400X, respectivamente. Sendo assim, como principais diferenças, destaca-se que, enquanto (MATOS *et al.*, 2019) utiliza um conjunto de dados inicial para a filtragem de característica por meio de um SVM, este trabalho realiza essa etapa por meio de uma rede CNN. Além disso, a rede utilizada para transferência de conhecimento por (MATOS *et al.*, 2019) é pré-treinada fora do contexto histopatológico, sendo que este trabalho realiza o pré-treinamento partir dos dados utilizando a CNN VGG16 pré-treinada com dados do *ImageNet* para treinamento de uma rede que classifica imagens pertencentes ao contexto histopatológico, vale ressaltar que a arquitetura CNN utilizada neste trabalho é diferente da utilizada em (MATOS *et al.*, 2019).

3.4 Classification of Histopathological Images for Early Detection of Breast Cancer Using Deep Learning (SENAN *et al.*, 2021)

No trabalho de SENAN *et al.*(2021), os autores propõem uma abordagem baseada no uso de CNN *AlexNet* pré-treinada com base no conjunto de dados *ImageNet*, onde aplicam transferência de conhecimento a uma rede CNN para extrair recursos de imagens histopatológicas pertencentes ao conjunto de dados *BreakHis* e classificam as imagens nas classes de tumores benignos e malignos. Para isso, na etapa de pré-processamento, os autores utilizaram técnicas de normalização de manchas nas imagens e alteraram o contraste das mesmas, com o objetivo de melhorar a extração de características. Após essa etapa, os mesmos fizeram o uso da técnica *DataAugmentation* para treinamento da rede com base em imagens de diferentes escalas. Por fim, as camadas da rede pré-treinada são conectadas às camadas do classificador final juntamente com os recursos extraídos para a classificação binária.

Como resultados, quatro experimentos foram realizados de acordo com os fatores de magnitude de 40X, 100X, 200X e 400X no conjunto de dados *BreakHis*, com base no

treinamento de 80% dos dados e 20% para teste, obtendo acurácia de 95%, sensibilidade de 97%, especificidade de 90% e AUC de 99,36%. Em análise, com relação às diferenças entre o trabalho de (SENAN *et al.*, 2021) e o presente trabalho, pode-se destacar o uso de uma rede pré-treinada fora do contexto histopatológico para a transferência de conhecimento e o uso da arquitetura *AlexNet*. Enquanto, o presente trabalho faz o uso de uma rede VGG16 pré-treinada nos dados do *ImageNet* e com dados pertencente ao contexto histopatológico. Além disso, (SENAN *et al.*, 2021) utilizam técnicas de normalização nas imagens do mesmo conjunto de dados, enquanto este trabalho normaliza imagens do conjunto de dados histopatológico auxiliar *MSI vs MSS* com base nas imagens do conjunto *BrekHis*.

3.5 Análise Comparativa Entre os Trabalhos Relacionados e Este Trabalho

Como feito em (LI *et al.*, 2019), o presente trabalho realiza a classificação de imagens do conjunto de dados *BrekHis*. Porém, o trabalho mencionado realiza a tarefa de multi-classificação das imagens em 4 classes diferentes, enquanto este trabalho realiza classificação binária em câncer ou normalidade. Além disso, o (LI *et al.*, 2019) utiliza a técnica de transferência de cores entre imagens proposta por (REINHARD *et al.*, 2001), assim como o presente trabalho utiliza. Entretanto, diferentemente de (LI *et al.*, 2019), este trabalho utiliza transferência de cores entre o conjunto *BrekHis* e o conjunto de dados auxiliar *MSI vs MSS*, do qual realiza-se o pr-e-treinamento de VGG16 para transferência de conhecimento.

Assim como em (HAMEED *et al.*, 2020), este trabalho realiza classificação binária através de imagens de histologia da mama. Contudo, o trabalho citado classifica as imagens em duas classes específicas, sendo a classe carcinoma ou não carcinoma no conjunto de dados do Departamento de Patologia da Universidade de Colsanitas Colombia. Por outro lado, este trabalho realiza a classificação binária de câncer ou normalidade sem utilizar especificidade do tipo de câncer de mama a partir do conjunto *BreakHis*. Ademais, o trabalho em menção utiliza normalização dos dados a partir da proposta de (MACENKO *et al.*, 2009) e o presente trabalho utiliza a técnica de transferência de cor proposta por (REINHARD *et al.*, 2001).

Além disso, como realizado em (MATOS *et al.*, 2019) o presente trabalho faz o uso de transferência de conhecimento. Porém, enquanto (MATOS *et al.*, 2019) utiliza uma rede *Inception-v3* pré-treinada com base do conjunto *ImageNet*, este projeto utiliza uma rede VGG16 pré-treinada com dados do *ImageNet* e com o conjunto de dados pertencente ao contexto histopatológico. Ademais, enquanto (MATOS *et al.*, 2019) classifica as imagens do conjunto de

dados *BreakHis* em benignas ou malignas por meio de um SVM, este trabalho utiliza apenas a CNN VGG16 como classificador final.

Por fim, diferente do que foi efetuado em (SENAN *et al.*, 2021), este trabalho utiliza a rede de arquitetura VGG16 pré-treinada para a realização de transferência de conhecimento. Entretanto, diferente de (SENAN *et al.*, 2021), que utilizou CNN pré-treinada com dados do *ImageNet* para realizar transferência de conhecimento, este trabalho realiza transferência de conhecimento a partir de uma CNN pré-treinada com dados do *ImageNet* e dados histopatológicos de um conjunto de dados auxiliar. Ademais, (SENAN *et al.*, 2021) normaliza as cores das imagens do conjunto *BreakHis*, enquanto este trabalho realiza normalização de dados com transferência de cor para as imagens do conjunto de dados histopatológico auxiliar *MSI vs MSS* com base nas imagens do conjunto *BreakHis*. Ademais, é importante salientar que todos os trabalhos citados utilizaram a técnica de transferência de conhecimento para realizar a classificação final.

Abaixo, no Quadro 1, podem ser observadas características elencadas a partir dos trabalhos relacionados apresentados anteriormente e a sua comparação ao projeto exposto no presente trabalho.

Quadro 1 – Comparação entre os trabalhos relacionados e o proposto.

| | Arquitetura CNN | Técnica de transferência de cor | Conjunto de dados | Conjunto de dados experimental | Métricas de avaliação |
|-------------------------------|---------------------|---------------------------------|------------------------|--------------------------------|------------------------------------|
| (LI <i>et al.</i> , 2019) | <i>ResNet50</i> | Reinhard | <i>BioImaging 2015</i> | <i>ImageNet</i> | <i>precision</i> e macro-F |
| (HAMEED <i>et al.</i> , 2020) | <i>VGG</i> | Macenko | Hameed | <i>ImageNet</i> | <i>precision</i> e F-score |
| (MATOS <i>et al.</i> , 2019) | <i>Inception-v3</i> | Não específica | <i>BreakHis</i> | <i>ImageNet</i> | <i>precision</i> |
| (SENAN <i>et al.</i> , 2021) | <i>AlexNet</i> | Reinhard | <i>BreakHis</i> | <i>ImageNet</i> | <i>accuracy, precision, recall</i> |
| Este Trabalho | <i>VGG16</i> | Reinhard | <i>BreakHis</i> | <i>MSI vs MSS</i> | <i>accuracy</i> e F-score |

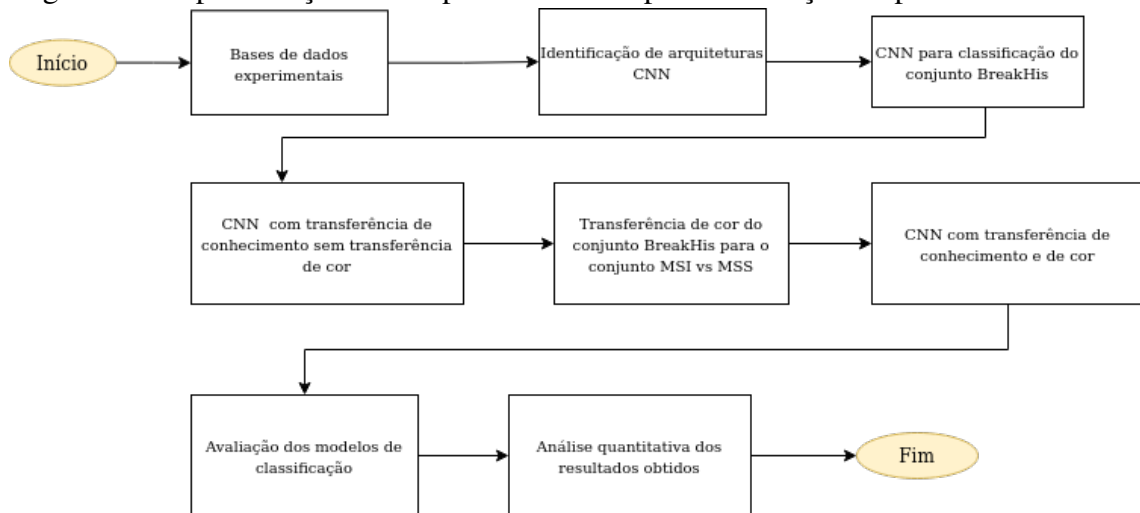
Fonte: Elaborado pela autora deste trabalho.

A técnica de transferência de cor *Reinhard* é proposta em Reinhard *et al.* (2001), e a técnica *Macenko* é proposta em Macenko *et al.* (2009). O conjunto de dados *Hameed* é proposto em Hameed *et al.* (2020) e o conjunto *Bioimaging 2015* é proposto em Pêgo e Aguiar (2015).

4 PROCEDIMENTOS METODOLÓGICOS

Neste capítulo, são explanadas as etapas necessárias que foram seguidas para atingir os objetivos visados neste trabalho. Abaixo, na Figura 5, são representadas essas etapas, sendo elas: 1) Coleta das bases de dados experimentais; 2) Identificação das arquiteturas mais utilizadas para classificação de imagens histopatológicas; 3) Implementação da CNN para classificação do conjunto *BreakHis*; 4) Construção de um classificador baseado em transferência de conhecimento sem transferência de cor; 5) Aplicação da técnica de transferência de cor entre o conjunto *BreakHis* e *MSI vs MSS*; 6) Construção de um classificador baseado em transferência de conhecimento e transferência de cor; 7) Avaliação dos modelos de classificação; 8) Análise quantitativa dos resultados obtidos.

Figura 5 – Representação das etapas necessárias para a execução do presente trabalho.



Fonte: Elaborada pela autora deste trabalho.

Vale ressaltar que essas etapas são descritas no decorrer deste capítulo, onde: na Seção 4.1 é descrito como se deu a coleta das bases experimentais utilizadas neste trabalho, na Seção 4.2 descreve-se como foi realizada a escolha da arquitetura CNN utilizada no presente trabalho, na Seção 4.3 é explicado como foi realizada a implementação da CNN para classificação do conjunto *BreakHis*, já na Seção 4.4 é explicado como se deu a implementação do classificador do conjunto *BreakHis* baseado em transferência de conhecimento sem transferência de cor, na Seção 4.6 explica-se como foi construído o classificador do conjunto *BreakHis* baseado em transferência de cor e transferência de conhecimento, na Seção 4.7 é explicada a forma de avaliação dos modelos preditivos que foram construídos, seguida pela Seção 4.8 que é referente à análise dos resultados obtidos por meio da avaliação dos modelos preditivos.

4.1 Coleta das Bases de Dados Experimentais

Esta seção descreve como foi realizada a coleta das duas bases experimentais que foram utilizadas neste trabalho: *BreakHis* (SPANHOL *et al.*, 2015) e a base *MSI vs MSS* (KATHER, 2019), bem como os detalhes que cada uma contém.

4.1.1 Conjunto de Dados *BreakHis*

O conjunto de dados *BreakHis*, utilizado neste trabalho, foi construído por Spanhol *et al.* (2015) e é mantido pelo Laboratório de P&D - Anatomia Patológica e Citologia do estado do Paraná, no Brasil.

4.1.1.1 Características gerais

Atualmente, este conjunto de dados é composto por cerca de 7.909 imagens microscópicas, também conhecidas como histopatológicas, que contém detalhes do tecido da mama para identificação de tumores, que foram coletadas em cerca de 82 pacientes. Essas imagens estão divididas em diferentes níveis de zoom: 40X, 100X, 200X e 400X, contendo 2.480 imagens de tumores benignos e 5.429 malignas. Cada amostra tem 8 bits de profundidade de acordo com cada canal RGB em formato PNG. Este conjunto de dados foi coletado por meio do site oficial do Laboratório de Visão Robótica e Imagem da Universidade Federal do Paraná, onde foi necessário informar o e-mail institucional do autor deste trabalho e da Universidade que este pertence, para que fosse possível ter acesso a este conjunto de dados. Abaixo, na Tabela 1, é possível visualizar as características relacionadas à quantidade de imagens existentes nesse conjunto de dados de acordo com o nível de zoom.


Tabela 1 – Características do conjunto de dados *BreakHis*

| Nível de zoom | Imagens de tumores benignos | Imagens de tumores malignos | Total |
|---------------|-----------------------------|-----------------------------|-------|
| 40X | 652 | 1,370 | 1,995 |
| 100X | 644 | 1,437 | 2,081 |
| 200X | 623 | 1,390 | 2,013 |
| 400X | 588 | 1,232 | 1,820 |
| Total | 2,480 | 5,429 | 7,909 |

Fonte: Adaptado (UFPR, 2016)

Na Figura 6 é possível observar uma amostra pertencente ao conjunto *BreakHis* com o fator de 200X, de um tumor maligno do tipo carcinoma mucinoso (MC).

Figura 6 – Amostra de tumor maligno pertencente ao conjunto *BreakHis*



Fonte: Conjunto *BreakHis* (SPANHOL *et al.*, 2015)


4.1.1.2 Desbalanceamento dos dados

O conjunto de dados *Breakhis* é desbalanceado contendo mais imagens de tumores malignos do que benignos. Dessa forma, para que esse desbalanceamento não afetasse no treinamento dos modelos preditivos, a técnica de *Synthetic Minority Over-sampling Technique* (SMOTE) que gera diversos recortes de imagens proposta por (CHAWLA *et al.*, 2002), que gera amostras da classe minoritária, com objetivo de igualá-la à classe majoritária em número de amostras. Assim, após a aplicação da técnica SMOTE, o número de amostras benignas passou de 2,480 para 5,429, um número igual a quantidade de amostras malignas.

4.1.2 Conjunto de Dados MSI vs MSS

Proposto por Kather (2019), o conjunto de dados MSI (*Microsatellite Instable*) vs MSS (*Microsatellite Stable*), nome referente a dois tipos de procedimentos utilizados para analisar o nível de instabilidade de um tumor, contém imagens histopatológicas de câncer colorretal e gástrico obtidas por meio de pacientes que participaram de procedimentos de biópsia para diagnosticar um desses tipos de câncer. Este conjunto de dados contém cerca de 192.321 imagens em formato jpg com manchas classificadas nas categorias de câncer descritas acima, derivadas de lâminas para diagnóstico com substâncias de formalina e parafina. Além disso, ressalta-se que, para utilização neste trabalho, o conjunto de dados MSI vs MSS foi obtido por meio do repositório Zenodo (2021). Na Figura 7, é ilustrada uma amostra pertencente à classe MSS (*Microsatellite Stable*).

Figura 7 – Amostra pertencente à categoria MSS.



Fonte: (KATHER, 2019)

4.2 Identificação das Arquiteturas mais Utilizadas para Classificação de Imagens Histopatológicas

Para a escolha da arquitetura CNN que foi utilizada neste trabalho, inicialmente foram considerados os resultados obtidos pelas arquiteturas utilizadas nos trabalhos relacionados, considerando que os mesmos tinham o objetivo em comum de classificar as imagens do conjunto *BreakHis*. Visto isso, foi realizado um mapeamento dos trabalhos, juntamente com as arquiteturas utilizadas e os resultados obtidos, como pode ser observado na Tabela 2.

Tabela 2 – Mapeamento das arquiteturas utilizadas nos trabalhos relacionados.

| Trabalho | Arquitetura | <i>f-score</i> |
|-------------------------------|--------------------|-----------------------|
| (SENAN <i>et al.</i> , 2021) | <i>AlexNet</i> | 93% |
| (LI <i>et al.</i> , 2019) | <i>ResNet50</i> | 89,14% |
| (HAMEED <i>et al.</i> , 2020) | VGG16 e VGG19 | 91,63% e 90,31% |

Fonte: Autora deste trabalho.

O mapeamento acima mostra que dentre as arquiteturas utilizadas, a *AlexNet* obteve o melhor *f-score* de 93%. Porém, levando em consideração que este trabalho utilizou o Keras para implementação e que esta biblioteca não tem a arquitetura *AlexNet* pré-treinada com pesos do *ImageNet*, a arquitetura escolhida foi a VGG16 que obteve o segundo melhor *f-score* de 91,63%.

4.3 Implementação da CNN para Classificação do Conjunto BreakHis

A implementação da CNN de classificação do conjunto *BreakHis* foi realizada na GPU gratuita da plataforma *Kaggle*, assim como os demais experimentos realizados neste trabalho, em decorrência da rapidez de treinamento que se dá com o uso de GPU e por limitações de hardware. Além disso, utilizou-se a linguagem *Python* para implementação da rede, juntamente com a biblioteca *Keras*.

Inicialmente, foi realizada a leitura da base de dados balanceada que passou de 7909 amostras para 10858, dividida nas classes de imagens de tumores malignos e benignos. Ou seja, para verificar a existência de câncer ou normalidade. Na etapa de treinamento, foram utilizados 80% dos dados, equivalente a cerca de 8143 amostras e 20% para teste, equivalente a 2715. Como o conjunto *BreakHis* não é considerado um conjunto com uma grande quantidade de dados, o *Batch size* escolhido foi de 16, para que o número de dados por época pudesse contribuir no processo de atualização dos pesos, treino e validação do modelo.

O algoritmo de otimização escolhido foi o *stochastic gradient descent* (SGD) em função de alguns testes executados ele ofereceu menos variância com o uso de regularização e camada de *Dropout*. Vale destacar que essa configuração foi utilizada em todas as redes implementadas neste trabalho. Ademais, vale ressaltar que esta rede não contou com carregamento de pesos pré-treinados, pois um dos principais objetivos da implementação deste experimento foi obter um modelo base para comparar os resultados obtidos pelas demais abordagens que foram realizadas e que serão explanadas nas demais seções.

4.4 Construção de um Classificador Baseado em Transferência de Conhecimento sem Transferência de Cor

Nesta seção, serão detalhadas as etapas que foram seguidas para a construção do classificador a partir da utilização de transferência de conhecimento sem transferência de cor.

4.4.1 Implementação da CNN com Imagens do Conjunto MSI vs MSS

A implementação da CNN para classificar as imagens do conjunto *MSI vs MSS* também foi realizada em *Python* utilizando a biblioteca *Keras*, assim como os demais experimentos deste trabalho. Em relação à configuração desta rede, foi utilizada a rede VGG16 do pacote *Keras Applications* contando com o carregamento dos pesos pré-treinados do conjunto *ImageNet*,

adicionando uma camada de *Flatten* para reduzir a dimensionalidade dos dados e compactá-los, uma camada de regularização e de *Dropout* para controlar o *overfitting* ao longo do treinamento e validação do modelo e, por último, adicionando uma camada de classificação final.

Como trata-se da utilização de uma rede pré-treinada, algumas camadas foram congeladas para que seus pesos não fossem re-treinados. As camadas que não foram congeladas foram utilizadas para que pudessem ser adaptadas aos dados do conjunto MSI vs MSS e contribuíssem na classificação. Além disso, vale ressaltar que este experimento também foi realizado na GPU do *Kaggle* que tem um limite de 8 horas por sessão e em alguns testes realizados utilizando a quantidade total dos dados em apenas 10 épocas ultrapassava o limite de tempo por sessão e os *scores* (acurácia e *f1-score*) não chegavam a valores altos, o que pode ter sido prejudicial para o treinamento do modelo, já que a quantidade de épocas contribui com o aprendizado do modelo em relação à atualização de pesos e parâmetros.

Dessa forma, este experimento contou com a utilização de cerca de 40000 imagens, sendo 80% para treinamento e 20% para teste. Devido a isso, o *Batch size* utilizado foi de 64 para que o número de dados por época fosse suficiente para contribuir com o treinamento e validação do modelo. Por fim, os melhores pesos obtidos durante o treinamento foram exportados para serem utilizados no experimento da Seção 4.4.2.

4.4.2 Aplicação de Transferência de Conhecimento a Partir do Modelo MSI vs MSS

A CNN para classificação do conjunto *BreakHis* baseada em transferência de conhecimento foi realizada com a mesma quantidade de dados da CNN baseline 1085 com 80% dos dados para treinamento e 20% para teste. A construção do modelo foi baseada na importação do modelo implementado na Seção 4.4 e com o arquivo contendo os melhores pesos obtidos durante a execução do modelo.

A configuração desta rede contou com o congelamento das camadas de classificação do modelo importado, sendo adicionadas uma camada de *Flatten*, de regularização e de *Dropout*, juntamente com a camada de classificação final. Em relação ao valor do *Batch size* foi o mesmo utilizado na CNN baseline.

4.5 Aplicação da Técnica de Transferência de Cor do Conjunto *BreakHis* Para *MSI vs MSS*

Nesta seção, serão explicados os passos seguidos para aplicar transferência de cor do conjunto *BreakHis* para o conjunto *MSI vs MSS*.

4.5.1 Aplicação de Transferência de Cor

Para aplicar a transferência de cor das imagens do conjunto de dados *BreakHis* para o conjunto *MSI vs MSS* foi utilizada como fonte uma implementação da técnica de transferência de cor de (REINHARD *et al.*, 2001) na linguagem Python feita por (VERMA, 2018), utilizando a biblioteca *Numpy* para computação numérica e a biblioteca *OpenCV* para tarefas relacionadas à visão computacional e manipulação de imagens. O código-fonte utilizado como base recebia uma imagem fonte e uma imagem destino, onde o objetivo era transferir cor da imagem fonte para a imagem destino para gerar uma terceira imagem com as cores predominantes da imagem fonte, mas com as características da imagem destino. Em questão de adaptação deste código-fonte, foi utilizada uma amostra do conjunto *BreakHis* para representar as demais imagens desse conjunto de dados e a partir desta transferir cor para as imagens do conjunto *MSI vs MSS* com a mesma quantidade utilizada na CNN de classificação da Seção 4.6.

4.6 Construção de um Classificador Baseado em Transferência de Conhecimento com Transferência de Cor

Nesta seção, será explicado como foi realizada a implementação do classificador baseado em transferência de conhecimento e transferência de cor, seguindo as etapas de pré-treinamento da CNN baseada no conjunto de imagens com transferência de cor e implementação de transferência de conhecimento.

4.6.1 Implementação da CNN Baseada no Conjunto de Imagens com Transferência de Cor

Após aplicar transferência de cor das imagens do conjunto *BreakHis* para o *MSI vs MSS*, como explicado na Seção 4.5, foi feita a implementação da CNN com base nessas imagens obtidas através da aplicação de transferência de cor seguindo a mesma configuração da rede construída na Seção 4.4.2 que utilizou as imagens do conjunto *MSI vs MSS* sem transferência de

cor. Além disso, os melhores pesos obtidos durante o treinamento e o modelo foram importados para serem utilizados na construção do classificador baseado em transferência de conhecimento e transferência de cor que será explicado na Seção 4.6.2.

4.6.2 Implementação de Transferência de Conhecimento

Com o treinamento da CNN baseada em transferência de cor, explicada anteriormente na Seção 4.6.1, o modelo e os seus melhores pesos foram importados na construção da CNN baseada em transferência de conhecimento e transferência de cor para classificação das imagens do conjunto *BreakHis*. Assim como as redes anteriores, utilizou-se a mesma quantidade de imagens com 80% dos dados para treinamento e 20% para teste. No que se refere a configuração da rede, seguiu-se a mesma utilizada na CNN baseline da Seção 4.3 e da CNN sem transferência de cor da Seção 4.4.2.

4.7 Avaliação dos modelos preditivos

A avaliação dos três modelos preditivos que foram construídos durante a execução deste trabalho, consistiu na extração de duas principais métricas: acurácia e f1-score. Dessa maneira, ao final da execução de cada modelo, foi extraído o valor dessas métricas, para oferecer uma visão geral do quanto o modelo harmoniza precisão e revocação com relação ao *f-score*.

4.8 Análise Quantitativa dos Resultados Obtidos

A análise dos resultados obtidos por meio das abordagens descritas nas seções anteriores ocorreu após a extração da acurácia e do *f-score* de cada modelo que foi construído. Para a análise, foi realizado um mapeamento de cada modelo juntamente com sua acurácia e *f-score* em questão de comparar o desempenho das três abordagens: sem transferência de conhecimento e de cor, com transferência de conhecimento sem transferência de cor e com transferência de conhecimento e de transferência de cor.


5 RESULTADOS E DISCUSSÕES

Neste capítulo, serão apresentados os resultados obtidos com o uso das abordagens realizadas durante a execução deste trabalho.

5.1 Experimento para escolha da arquitetura CNN


Como relatado na Seção 4.3, a arquitetura utilizada neste trabalho foi a VGG16. Esta escolha se deu pela consideração dos resultados obtidos com a utilização desta e analisando o seu comportamento no controle de *overfitting*. Dessa forma, nas Figuras 8 e 9 é possível visualizar o comportamento do uso da ResNet50 e da VGG16 no controle do *overfitting*.

Figura 8 – Experimento com arquitetura ResNet50



Fonte: Autora deste trabalho.

Figura 9 – Experimento com arquitetura VGG16



Fonte: Autora deste trabalho.


Em análise, mesmo com um maior número de épocas de treinamento, no caso 50, a arquitetura ResNet50 dificultou o controle de *overfitting* mesmo com a utilização de camadas de *dropout* e regularização.

5.2 Experimento para CNN de Classificação do Conjunto *BreakHis*

A implementação da CNN para para classificação do conjunto *BreakHis*, como relatado na Seção 4.3, contou com a utilização de camadas de *dropout* e regularização. Dessa forma, na Figura 10, é representado o experimento realizado sem utilização de *dropout* e regularização, a fim de analisar o efeito de contribuição do uso dessas duas camadas na implementação do modelo. Já na Figura 11 é representado o comportamento da acurácia e a *loss* de treino e de


validação ao longo de 15 épocas de execução do modelo. Onde, em ambos os gráficos, os pontilhados representam a acurácia e *loss* de treino, enquanto a linha contínua representa a acurácia e *loss* de validação. Além disso, ressalta-se que no eixo x são plotados os valores de acurácia e *loss* de acordo com o número de épocas que é plotado no eixo y.

Figura 10 – Acurácia e *loss* da CNN *BreakHis* baseline sem *dropout* e regularização



Fonte: Autora deste trabalho.

Figura 11 – Acurácia e *loss* da CNN *BreakHis* baseline com *dropout* e regularização



Fonte: Autora deste trabalho.


Em análise, é possível visualizar que a abordagem com *dropout* e regularização permitiu que a acurácia de validação chegasse a valores mais altos que a de treino, ocasionando em um problema de *underfitting*. Por outro lado, a *loss* inicia-se com valores altos tanto no treino e na validação do modelo. Já a abordagem sem utilização de *dropout* e regularização apresenta menos variação com relação à acurácia e a *loss* de treino e validação.

5.3 Experimento para Construção da CNN com Imagens do Conjunto MSI vs MSS

Como relatado na Seção 4.4, a CNN para classificação do conjunto MSI vs MSS foi executada com o número de 30 épocas e contou com a utilização de *dropout* e regularização. Na Figura 12, representa-se o comportamento do modelo sem o uso de *dropout* e regularização. Já na Figura 13, é representado o comportamento da acurácia e a *loss* de treinamento e validação


do modelo utilizando *dropout* e regularização.

Figura 12 – Acurácia e loss da CNN *MSI vs MSS* sem *dropout* e regularização



Fonte: Autora deste trabalho

Figura 13 – Acurácia e loss da CNN *MSI vs MSS* com *dropout* e regularização



Fonte: Autora deste trabalho


Em análise, o uso de camadas de dropout e regularização apresentou pouca variação na acurácia de validação quando comparada à acurácia de treino. Em relação à *loss* de treino e validação, iniciou-se com altos valores a *loss* de validação apresentou um comportamento próximo ao da *loss* de treino. Ademais, na Figura 12 a acurácia de treino e validação apresentou variação nas últimas épocas, assim como a *loss* de validação que também começou a se distanciar da *loss* de treino com valores mais altos.

5.4 CNN *BreakHis* com Transferência de Conhecimento

Como descrito na Seção 4.6.2, a CNN para classificação do conjunto *BreakHis* também contou com a utilização de *dropout* e regularização. Abaixo, as Figuras 15 e 14 representam o comportamento da acurácia e da *loss* de treino e validação com base no uso ou

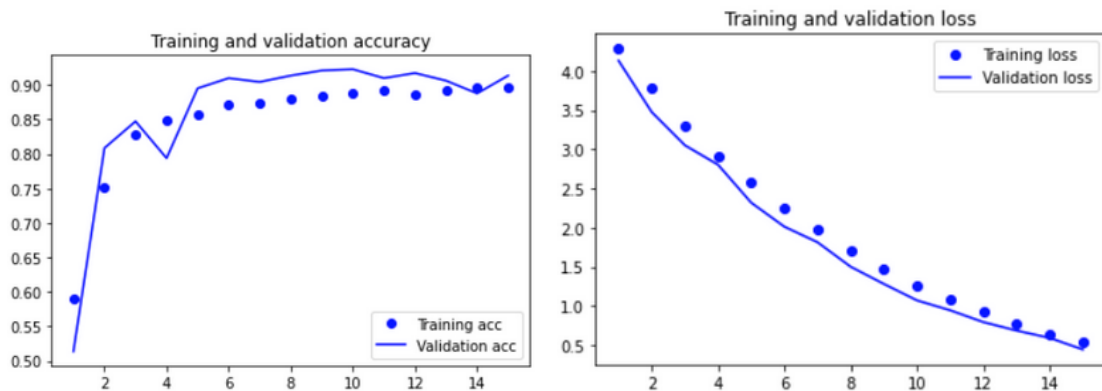
não uso dessas camadas de *dropout* e regularização ao longo de 15 épocas.

Figura 14 – Acurácia de treino e validação sem *dropout* e regularização



Fonte: Autora deste trabalho

Figura 15 – Acurácia de treino e validação com *dropout* e regularização




Fonte: Autora deste trabalho

A abordagem com utilização de camadas de *dropout* e regularização apresentou menor distanciamento entre os valores da acurácia e da *loss* de treinamento e de validação do modelo. Além disso, é possível perceber que a abordagem sem utilização de *dropout* e regularização mostra que a acurácia e a *loss* de validação apresentou maior variação com relação ao treinamento do modelo.

5.5 Experimento de Transferência de Cor

Abaixo, na Figura 16 o exemplo da aplicação da técnica de transferência de cor do conjunto *BreakHis* para o conjunto *MSI vs MSS*, onde a primeira amostra pertence ao conjunto *BreakHis*, a segunda ao conjunto *MSI vs MSS* e a última é a imagem resultante da aplicação da técnica de transferência de cor.

Figura 16 – Transferência de cor do conjunto *BreakHis* para o conjunto *MSI vs MSS*

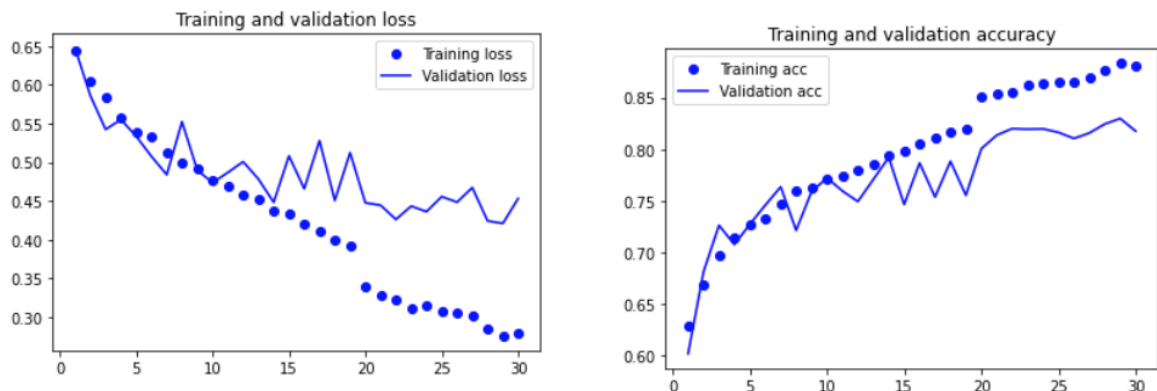


Fonte: Autora deste trabalho.

5.6 CNN *MSI vs MSS* com Transferência de Conhecimento e de Cor


A seguir, nas Figuras 18 e 17 são mostradas o comportamento da acurácia e da *loss* de treinamento e validação, sem e com a utilização de *dropout* e regularização ao longo de 30 épocas.

Figura 17 – Acurácia e *loss* de treino e validação sem *dropout* e regularização



Fonte: Autora deste trabalho.

Figura 18 – Acurácia e *loss* de treino e validação com *dropout* e regularização



Fonte: Autora deste trabalho.


Em análise, a abordagem sem utilização de *dropout* e regularização apresentou

variação entre a acurácia de treino e de validação, assim como a *loss* de treino e validação ao longo das últimas épocas de execução do modelo como mostra na Figura 17.

5.7 CNN *BreakHis* com Transferência de Conhecimento e de Cor


Abaixo, nas Figuras 20 e 19, é representado o comportamento da acurácia e da *loss* de treinamento e de validação do modelo de classificação do conjunto *BreakHis* com transferência de conhecimento e de cor, contando com a abordagem de utilização de camadas de *dropout* e regularização ao longo de 15 épocas de execução do modelo.

Figura 19 – Acurácia e *loss* de treino e validação CNN *BreakHis* com transferência de cor sem *dropout* e regularização



Fonte: Autora deste trabalho.

Figura 20 – Acurácia e *loss* de treino e validação CNN *BreakHis* com transferência de cor com *dropout* e regularização



Fonte: Autora deste trabalho.

A Figura 19 mostra que o experimento sem utilização das camadas de *dropout* e de regularização apresentou alta variação entre a acurácia e a *loss* de treinamento e validação do

modelo. Dessa forma, por se tratar de uma rede com maior número de parâmetros, a abordagem com uso de *dropout* e de regularização conseguiu controlar melhor o *overfitting* do modelo.

5.8 Comparativo dos resultados obtidos por meio de cada abordagem

Nesta Seção, será exibido e relatado um comparativo entre os resultados obtidos por meio das abordagens com e sem transferência de conhecimento e de cor. Na Tabela 3, é feito um mapeamento dos resultados obtidos por meio de cada abordagem. Além disso, a Tabela está ordenada de acordo com a ordem de implementação.

Tabela 3 – Comparativo dos resultados obtidos

| Abordagem | Acurácia | <i>f-score</i> |
|---|-----------------|-----------------------|
| CNN Baseline | 86% | 87% |
| CNN <i>MSI vs MSS</i> com transferência de conhecimento | 83% | 86% |
| CNN <i>BreakHis</i> com transferência de conhecimento | 91% | 91% |
| CNN <i>MSI vs MSS</i> com transferência de cor e conhecimento | 80% | 82% |
| CNN <i>BreakHis</i> com transferência de cor e conhecimento | 93% | 92% |

Fonte: Autora deste trabalho.

Em análise, a abordagem que obteve os melhores resultados foi a que utilizou transferência de conhecimento e transferência de cor para classificar as imagens do conjunto *BreakHis*, onde foi obtido 93% de acurácia e 92% de *f-score*. Além disso, vale ressaltar que a abordagem utilizando apenas transferência de conhecimento também obteve bons resultados, onde foi obtido 91% de acurácia e de *f-score*.

6 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho teve como principal objetivo propor e avaliar uma solução para a detecção de câncer de mama em imagens histopatológicas de câncer de mama, utilizando Redes Neurais Convolucionais (CNN 's) com as técnicas de transferência de conhecimento e transferência de cor. Desta forma, foram implementados ao todo 4 modelos seguindo o uso da arquitetura VGG16, dos quais 1 modelo sem transferência de conhecimento e transferência de cor, 2 utilizando transferência de conhecimento e sem transferência de cor e 2 com transferência de conhecimento e de cor. Cada rede contou com uso de camadas de regularização e *dropout* para controle *overfitting*. Além disso, o número de épocas variou entre 15 e 30, sendo os modelos utilizados para extrair os melhores pesos foram treinados utilizando 30 épocas.

Com relação às principais dificuldades encontradas na execução deste trabalho, pode se destacar o *hardware* utilizado, que apresenta pouco poder de processamento e por isso todos os experimentos foram realizados na GPU gratuita do *Kaggle*. Com relação à utilização da GPU do *Kaggle*, a quantidade de imagens utilizadas no treinamento dos modelos foi reduzida, devido a alguns experimentos de testes terem ultrapassado o tempo limite de uso. Além disso, com relação à análise dos resultados obtidos por meio dessas abordagens, pode ser destacado que a utilização de transferência de conhecimento juntamente com transferência de cor obteve os melhores resultados, sendo 93% de acurácia e 92% de *f-score*.

Dessa maneira, este trabalho mostrou que o uso das técnicas de transferência de conhecimento e de cor podem contribuir para a melhoria da classificação das imagens do conjunto *BreakHis*, visando contribuir com estudos e pesquisas que utilizam técnicas de aprendizado profundo na classificação de imagens histopatológicas. Vale ressaltar que todas as implementações realizadas neste trabalho podem ser encontradas em repositório público no GitHub ¹.

Em relação a trabalhos futuros, visa utilizar outras arquiteturas CNN para testar as abordagens seguidas neste trabalho, tais como: *EfficientNet* e demais arquiteturas contidas no *Keras Applications*, com o objetivo de analisar o comportamento de outras arquiteturas na classificação de imagens histopatológicas que possam oferecer melhores resultados. Além disso, visa-se aumentar o número de épocas de treinamento a fim de observar a atenuação do *overfitting* e obtenção de valores mais altos para acurácia e *f-score*.

¹ <https://github.com/kelyAna/TCC>

REFERÊNCIAS

ACADEMY, D. S. **Introdução à Redes Neurais**. [S. l.:s.n.], 2021. Disponível em: <https://www.deeplearningbook.com.br/introducao-as-redes-neuraisconvolucionais/>. Acesso em: 07 jul.2021.

ANKILE, L. L.; HEGGLAND, M. F.; KRANGE, K. **Deep Convolutional Neural Networks: A survey of the foundations, selected improvements, and some current applications**. [S. l.: s. n.], 2020.

BERNARDES, N. B.; SÁ, A. C. F. de; FACIOLI, L. de S.; FERREIRA, M. L.; SÁ, O.R.de; COSTA, R. de M. Câncer de mama x diagnóstico/breast cancer x diagnosis. **ID on line Revista de Psicologia**,[S.I], v. 13, n. 44, p. 877–885, 2019.

BOASQUEVISQUE, P. C. R. **Classificação do grau histológico de malignidade em câncer de mama utilizando programas de análise automatizada de imagens e aprendizado de máquina**. Tese (Doutorado em Ciências Farmacêuticas-Pós-Graduação em Ciências Farmacêuticas) – Universidade de Vila Velha, Vila Velha, 2020.

BOCHIE, K.; GILBERT, M. da S.; GANTERT, L.; BARBOSA, M. d. S. M.; MEDEIROS, D. S. V. de; CAMPISTA, M. E. M. Aprendizado profundo em redes desafiadoras: Conceitos e aplicações. **Sociedade Brasileira de Computação**. [S.I], 2020.

BOUREAU, Y.-L.; PONCE, J.; LECUN, Y. A theoretical analysis of feature pooling in visual recognition. In: **Proceedings of the 27th international conference on machine learning (ICML-10)**, [S.I], 111-118 p., 2010.

CHAWLA, N. V.; BOWYER, K. W.; HALL, L. O.; KEGELMEYER, W. P. SMOTE: synthetic minority over-sampling technique. **Journal of artificial intelligence research**. [S.I], v. 16, p. 321–357 , 2002.

CRUZ, A. R. d. S. et al. **Uma estratégia para reconhecimento de sinais de Língua Brasileira de Sinais utilizando aprendizado profundo**. Manaus: Universidade Federal do Amazonas, 2020.

FARIA, E. d. **Redes Neurais Convolucionais e Máquinas de Aprendizado Extremo Aplicadas ao Mercado Financeiro Brasileiro**. Tese (Programa de Pós-graduação em Engenharia Civil) – COPPE, da Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2018.

FUKUSHIMA, K. **Neocognitron: A hierarchical neural network capable of visual pattern recognition**. [S. I.]: Elsevier, 1988. v. 1, p. 119–130.

HAMEED, Z.; ZAHIA, S.; GARCIA-ZAPIRAIN, B.; AGUIRRE, J. J.; VANEGAS, A. M. Breast cancer histopathology image classification using an ensemble of deep learning models. **Sensors**. [S.I], v. 20, p. 4373, 2020.

INCA. **Conceito e Magnitude**. [S. l.], 2020. Disponível em: <https://www.inca.gov.br/>, 2020. Acesso em: 20 jul.2021.

IZBICKI, R.; SANTOS, T. M. dos. **Aprendizado de máquina: uma abordagem estatística**. [S. l.]: Rafael Izbicki, 2020.

JÄHNE, B.; HAUSSECKER, H.; GEISSLER, P. **Handbook of computer vision and applications**. [S. l.]: Citeseer, 1999. v. 2.

KARAMIZADEH, S.; ABDULLAH, S. M.; MANAF, A. A.; ZAMANI, M.; HOOMAN, A. An overview of principal component analysis. **Journal of Signal and Information Processing**. [S.l.], v. 4, p. 173, 2013.

KATHER, J. N. **Histological images for MSI vs. MSS classification in gastrointestinal cancer, FFPE samples**. [S. l.]: Zenodo, 2019. Disponível em: <https://doi.org/10.5281/zenodo.2530835>. Acesso em: 20 jul. 2021.

KERR, D. A. The CIE XYZ and xyY color spaces. **Colorimetry**, [S.l.], v. 1, p. 1–16, 2010.

LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. In: **Proceedings of the IEEE**. [S.l.], v. 86. p. 2278–2324, 1998.

LI, Y.; WU, J.; WU, Q. Classification of breast cancer histology images using multi-size and discriminative patches based on deep learning. **IEEE Access**. [S.l.], p. 21400–21408, 2019.

LI, Z.; LIU, F.; YANG, W.; PENG, S.; ZHOU, J. A survey of convolutional neural networks: analysis, applications, and prospects. **IEEE Transactions on Neural Networks and Learning Systems**, [S.l.], 2021.

MACENKO, M.; NIETHAMMER, M.; MARRON, J. S.; BORLAND, D.; WOOSLEY, J. T.; GUAN, X.; SCHMITT, C.; THOMAS, N. E. A method for normalizing histology slides for quantitative analysis. In: **IEEE International Symposium on Biomedical Imaging: From Nano to Macro**. [S.l.], p. 1107–1110, 2009.

MARQUES, E. A. L. **Estudo sobre redes neurais de aprendizado profundo com aplicações em classificação de imagens**. [S. l.: s. n.], 2016.

MATOS, J. de; BRITTO, A. d. S.; OLIVEIRA, L. E.; KOERICH, A. L. Double transfer learning for breast cancer histopathologic image classification. In: **International Joint Conference on Neural Networks (IJCNN)**. [S.l.], p. 1-8, 2019.

MONARD, M. C.; BARANAUSKAS, J. A. **Conceitos sobre aprendizado de máquina: sistemas inteligentes-fundamentos e aplicações**. [S.l: s.n], 2003. v. 1. p. 32.

NAQA, I. E.; MURPHY, M. J. What is machine learning? **Springer**. [S.l.], p. 3–11, 2015.

OLIVEIRA, A. L. R.; MICHELINI, F. S.; SPADA, F. C.; PIRES, K. G.; COSTA, L. de O.; FIGUEIREDO, S. B. C. de; LEMOS, A. **Fatores de risco e prevenção do câncer de mama**. [S. l.]: Cadernos da Medicina-UNIFESO, 2020. v. 2.

PAN, S. J.; YANG, Q. A survey on transfer learning. In: **IEEE Transactions on knowledge and data engineering**. [S.l.], v. 22, p. 1345–1359, 2009.

PAULA, J. B. D. **Converting rgb images to lms cone activations**. [S. l.]: Citeseer, 2006.

PÊGO, A.; AGUIAR, P. Bioimaging 2015. In: **4th international symposium in applied bioimaging the pre-clinical challenge in 3d**. [S.l.], 2015.

PHUNG, V. H.; RHEE, E. J. et al. A high-accuracy model average ensemble of convolutional neural networks for classification of cloud image patches on small datasets. **Applied Sciences, Multidisciplinary Digital Publishing Institute**. [S.l.], v. 9, n. 21, p. 4500, 2019.

RAUBER, T. W. **Redes Neurais Artificiais**. Departamento de informática - Universidade Federal do Espírito Santo, v.29, 2005.

REINHARD, E.; ADHIKMIN, M.; GOOCH, B.; SHIRLEY, P. Color transfer between images. In: **IEEE Computer graphics and applications**. [S.l.], v. 21. p. 34–41, 2001.

REINHOLD, C. **Modelo de uma rede neural profunda para reconhecimento de texto manuscrito offline**. 2016. Disponível em: <https://docplayer.com.br/>. Acesso em: 12 jul. 2021.

ROCHA, C. V. M.; MAIA, L. B.; BRAZ JUNIOR, G. ; ALMEIDA, J. D. S. de; PAIVA, A. C. de. Otimização de CNN aplicada ao Diagnóstico de Melanoma. In: **Anais do XIX Simpósio Brasileiro de Computação Aplicada à Saúde**, [S.l.], p. 336-341, 2019.

RUDERMAN, D. L.; CRONIN, T. W.; CHIAO, C.-C. Statistics of cone responses to natural images: implications for visual coding. **Optical Society of America**. [S.l.], v. 15, p. 2036–2045, 1998.

SCURI, A. E. **Fundamentos da imagem digital**. Rio de Janeiro: Pontifícia Universidade Católica do Rio de Janeiro, p. 13, 1999.

SENAN, E. M.; ALSAADE, F. W.; AL-MASHHADANI, M. I. A.; THEYAZN, H.; AL-ADHAILEH, M. H. et al. Classification of histopathological images for early detection of breast cancer using deep learning. **Journal of Applied Science and Engineering**, Tamkang University Press, v. 24, n. 3, p. 323–329, 2021.

SERVI, Ç. D. M. **A Hospitalaristi des maltez**. [S.l.: s.n.], 2006.

SILVA, A. C. N.; SARAIVA, L. S.; LIMA, L. R. D. Importância do diagnóstico precoce

do câncer de mama em mulheres: uma revisão de literatura. In: **Encontro de Extensão, Docência e Iniciação Científica (EEDIC)**, [S.l.], v. 7, 2020.

SILVA, A. R. d. et al. **O papel da citologia no diagnóstico do câncer de mama**. Florianópolis: [s.n], 2019.

SPANHOL, F. A.; OLIVEIRA, L. S.; PETITJEAN, C.; HEUTTE, L. A dataset for breast cancer histopathological image classification. In: **IEEE transactions on biomedical engineering**. [S.l.], v. 63. p. 1455–1462, 2015.

THRUN, S.; PRATT, L. Learning to learn: Introduction and overview. **Springer**, [S.l.], p. 3– 17, 1998.

UFPR. **Breast Cancer Histopathological Database (BreakHis)**. [S. l.], 2016. Disponível em: <https://web.inf.ufpr.br/vri/>. Acesso em: 17 jul.2021.

ULHAQ, A.; KHAN, A.; GOMES, D.; PAUL, M. **Computer vision for covid-19 control: a survey**. arXiv preprint arXiv:2004.09420. [S.l.], 2020.

VERMA, K. **Super-Fast Color Transfer Algorithm**. [S. l.], 2018. Disponível em: <https://medium.com/codezest/>. Acesso em: 17 jul.2021.

WU, C.-Y.; MANMATHA, R.; SMOLA, A. J.; KRAHENBUHL, P. **Sampling Matters in Deep Embedding Learning**. [S. l.: s. n.], 2017.

ZENODO. **Zenodo**. [S. l.], 2021. Disponível em: <https://zenodo.org/>. Acesso em: 12 dez.2021.