



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Campus de São José do Rio Preto

Guilherme Gervaes

Exploração de Transformada Curvelet com Redes Neurais Convolucionais para Classificação de Imagens Histológicas

São José do Rio Preto
2021

Guilherme Gervaes

Exploração de Transformada Curvelet com Redes Neurais Convolucionais para Classificação de Imagens Histológicas

Trabalho de Conclusão de Curso (TCC) apresentado como parte dos requisitos para obtenção do título de Bacharel em Ciência da Computação, junto ao Conselho de Curso de Bacharelado em Ciência da Computação, do Instituto de Biociências, Letras e Ciências Exatas da Universidade Estadual Paulista “Júlio de Mesquita Filho”, Câmpus de São José do Rio Preto.

Orientador:

Prof. Dr. Leandro Alves Neves

São José do Rio Preto
2021

G385e Gervaes, Guilherme
Exploração de transformada curvelet com redes neurais convolucionais para classificação de imagens histológicas / Guilherme Gervaes. -- São José do Rio Preto, 2022
66 p. : il., tabs., fotos

Trabalho de conclusão de curso (Bacharelado - Ciência da Computação) - Universidade Estadual Paulista (Unesp), Instituto de Biociências Letras e Ciências Exatas, São José do Rio Preto
Orientador: Leandro Alves Neves

1. Ciência da computação. 2. Processamento de imagens. 3. Inteligência artificial Aplicações médicas. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca do Instituto de Biociências Letras e Ciências Exatas, São José do Rio Preto. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

Guilherme Gervaes

Exploração de Transformada Curvelet com Redes Neurais Convolucionais para Classificação de Imagens Histológicas

Trabalho de Conclusão de Curso (TCC) apresentado como parte dos requisitos para obtenção do título de Bacharel em Ciência da Computação, junto ao Conselho de Curso de Bacharelado em Ciência da Computação, do Instituto de Biociências, Letras e Ciências Exatas da Universidade Estadual Paulista “Júlio de Mesquita Filho”, Câmpus de São José do Rio Preto.

Comissão Examinadora:

Prof. Dr. Leandro Alves Neves
Orientador

Profa. Dra. Adriana Barbosa Santos

Profa. Dra. Rogéria Cristiane Gratão
de Souza

São José do Rio Preto
06 de dezembro de 2021

Agradecimentos

Agradeço primeiramente a minha família, em especial aos meus avós Shirley e José e minha mãe Adriana, por todo o apoio e confiança depositados em mim durante minha vida, apoio esse fundamental para meu ingresso no ensino superior e agora, para conclusão. Sem eles não teria chegado onde cheguei.

Agradeço ao meu orientador, Prof. Dr. Leandro Alves Neves, pela paciência, conselhos e orientações ao longo da graduação e particularmente dessa disciplina, e também pelo tempo e empenho depositados por ele durante o desenvolvimento do trabalho, me auxiliando a atingir meus objetivos ao final da disciplina.

Agradeço a todos os professores com quem tive aula durante formação básica e superior. Cada um de vocês tem participação no resultado deste trabalho, fornecendo ao longo dos anos as ferramentas necessárias para que hoje eu pudesse atingir uma das maiores metas que estabeleci.

Por fim, agradeço aos amigos que fiz durante todo esse período na graduação, os quais levarei para a vida toda. Agradeço pela companhia em todos os momentos, pelos conselhos em tempos difíceis, e por estarem lá pra viver isso tudo comigo. Sem vocês, não conseguiria.

Resumo

A extração de características e o método utilizado para processamento dos dados são partes fundamentais do processo de classificação de imagens digitais. Portanto, neste trabalho, foi observada a capacidade de classificação de uma rede neural convolucional quando adicionados coeficientes *curvelet* extraídos de imagens histológicas às imagens histológicas originais, em contextos de câncer colorretal, linfomas Não-Hodgkin, câncer de mama e tecido do fígado de ratos de ambos os gêneros e em diferentes estágios de vida, com objetivo de observar as melhores combinações de imagens histológicas e coeficientes *curvelet* no processo de classificação. Na etapa de extração de características foram obtidos os coeficientes *curvelet* das imagens histológicas e geradas sub-imagens compostas por esses coeficientes. A classificação, realizada pelo modelo pré-treinado da rede neural convolucional residual ResNet50, utilizou as imagens obtidas na extração de características combinadas às imagens histológicas e o desempenho foi comparado com a classificação utilizando apenas imagens histológicas. Os resultados mais promissores foram observados quando as sub-imagens geradas a partir dos coeficientes foram adicionadas às imagens histológicas originais, produzindo resultados até 10,70% superiores em acurácia e 25% superiores em precisão quando comparados aos observados na classificação utilizando somente imagens histológicas. A combinação das imagens histológicas originais com as sub-imagens geradas a partir dos coeficientes *curvelet* apresenta contribuição relevante para pesquisadores que se interessam pelo desenvolvimento de sistemas de apoio a diagnóstico que auxiliem profissionais na tomada de decisão nos domínios apresentados no trabalho.

Palavras-chave: Extração de características; transformada *curvelet*; ResNet50.

Abstract

Feature extraction and the method utilized for data processing are fundamental parts of the digital image classification process. Therefore, in this work, the classification capacity of a convolutional neural network was observed when curvelet coefficients extracted from histological images were added to the original histological images, in contexts of colorectal cancer, non-Hodgkin lymphomas, breast cancer and liver tissue of mice of both genders and at different stages of life in order to observe the best combinations of histological images and curvelet coefficients in the classification process. In the feature extraction step, curvelet coefficients of histological images were obtained and sub-images composed of these coefficients were generated. The classification, performed by the pre-trained residual convolutional neural network ResNet50, used the images obtained in the feature extraction step combined with the classification using only histological images. The most promising results were observed when the sub-images generated from the coefficients were added to the original histological images, producing results up to 10.70% superior in accuracy and 25% superior in precision when compared to those observed in the classification using only histological images. The combination of the original histological images with the sub-images generated from the curvelet coefficients presents a relevant contribution for researchers interested in the development of computer-aided systems that help professionals in decision-making in the domains presented in the work.

Keywords: Feature extraction; curvelet transform; ResNet50.

Lista de Ilustrações

2.1	Representação visual dos coeficientes <i>curvelet</i> de uma imagem. . . .	8
2.2	Exemplo de sub-imagem gerada a partir dos coeficientes <i>curvelet</i> de escala quatro e orientação quatro.	9
2.3	Exemplo de operação de convolução mostrando a área, filtro e resultado.	11
2.4	Exemplo de uma operação de <i>max pooling</i>	12
2.5	Exemplo de Rede Neural Residual com 34 camadas.	15
2.6	Exemplo de bloco residual utilizado nas redes neurais residuais, onde a <i>skip connection</i> acontece.	15
2.7	Arquitetura da Resnet50, rede neural residual.	16
2.8	Exemplo de imagens histológicas de câncer colorretal benigno (a) e maligno (b).	17
3.1	Exemplo de imagens histológicas de tumor colorretal benigno (a) e maligno (b).	26
3.2	Exemplo de imagens de linfoma não-Hodgkin do tipo CLL (a), FL (b) e MCL (c).	26
3.3	Exemplo de imagens histológicas de câncer de mama benigno (a) e maligno (b).	27
3.4	Exemplos de imagens de tecido do fígado de ratos de gênero masculino (a) e feminino (b).	27

3.5	Exemplo de imagens de tecido do fígado de ratos com um mês de idade (a), seis meses (b), 16 meses (c) e 24 meses (d).	28
3.6	Imagem da visão geral do esquema.	33
4.1	Comportamento da <i>loss</i> (a) e acurácia (b) no conjunto HIST.	40

Lista de Tabelas

3.1	Informações sobre os <i>datasets</i> utilizados neste trabalho.	28
3.2	Quantidade de imagens H&E e <i>curvelets</i> para treinamento e testes. . .	35
3.3	Quantidade de imagens H&E e <i>curvelets</i> por tipo de associação. . . .	38
4.1	Resultados observados das métricas para cada <i>dataset</i>	41
4.2	Melhores combinações de métricas para cada <i>dataset</i> e conjuntos . . .	42

Lista de Abreviaturas e Siglas

ANN Artificial Neural Networks

CAD Computer-Aided Diagnosis

CNN Convolutional Neural Networks

DSC Dice similarity coefficient

DT Decision Tree

GLCM Gray Level Co-occurrence Matrix

H&E Hematoxylin-Eosin

IoU Intersection over union

LBP Local Binary Pattern

ReLU Rectified Linear Unit

SVM Support-vector machine

WCE Wireless capsule endoscopy

WSI Whole-Slide Imaging

Sumário

Lista de Ilustrações	vii
Lista de Tabelas	ix
Lista de Abreviaturas e Siglas	x
Sumário	xi
1 Introdução	1
1.1 Justificativas e Motivação	3
1.2 Objetivos	4
1.3 Organização do trabalho	4
2 Referencial Teórico	6
2.1 Fundamentação Teórica	6
2.1.1 Extração de Características	7
2.1.2 Transformada Curvelet	7
2.1.3 Transformada Rápida Discreta Curvelet via Envelopamento	8
2.1.4 Artificial Neural Networks e Deep Learning	9
2.1.5 Redes Neurais Convolucionais	10
2.1.6 Camada Convolucional	11
2.1.7 Camada de Pooling	12
2.1.8 Funções de ativação	12

2.1.9	Transfer Learning	14
2.1.10	ResNet50	14
2.1.11	Imagens Histológicas	16
2.2	Trabalhos Relacionados	17
2.2.1	Transformada Curvelet	17
2.2.2	Redes Neurais Convolucionais	20
2.2.3	Considerações Sobre os Trabalhos Relacionados	23
3	Metodologia	25
3.1	Bases de imagens	25
3.2	Ferramentas de Implementação	29
3.3	Métricas de avaliação	29
3.3.1	Acurácia	30
3.3.2	Precisão	30
3.3.3	Sensibilidade	31
3.3.4	F-score	31
3.3.5	Loss	32
3.3.6	Classificações multi-classe	32
3.4	Visão Geral do método	33
3.4.1	Etapa 1 - Extração de Características	34
3.4.2	Etapa 2 - Treinamento e Testes	36
3.4.3	Etapa 3 - Cálculo das Métricas	37
3.5	Conjuntos de imagens	37
4	Resultados e Discussão	39
4.1	Resultados	39
4.2	Discussão	43
5	Conclusões	45

Capítulo 1

Introdução

Com os avanços de pesquisas em processamento de imagens digitais, uma das áreas beneficiadas foi a área de imagens médicas, em que foi observado o surgimento de diversos estudos sobre técnicas envolvidas no processo de diagnóstico de doenças, com exemplos em Miranda, Aryuni e Irwansyah (2016) e Deng et al. (2020). Ainda no contexto de auxílio a diagnóstico, imagens histológicas coloridas com Hematoxilina e Eosina (H&E) já auxiliam profissionais na detecção de diferentes tipos de tecido há mais de um século (FISCHER et al., 2008) e, com esse avanço de estudos na área, são exemplos de imagens que podem ser usadas para alimentar sistemas de auxílio a diagnóstico. Um dos exemplos desse avanço se dá no surgimento de *scanners* capazes de criar uma representação digital precisa do conteúdo das lâminas utilizadas em microscópios, processo esse chamado de *Whole-Slide Imaging* (WSI) (PANTANOWITZ et al., 2011). Com o surgimento de sistemas que implementam WSI, a qualidade de imagens histológicas disponíveis para processamento aumenta consideravelmente, possibilitando o uso dessas imagens digitais em sistemas de apoio a diagnóstico, ou sistemas CAD (*Computer-Aided Diagnosis*), que auxiliam o profissional de saúde na tomada de decisão.

A elaboração de sistemas CAD é constituída por diversas etapas e usa técnicas de processamento de imagens. Um exemplo de etapa é a extração de características,

amplamente pesquisada na área de desenvolvimento de sistemas CAD e composta por diversos métodos e métricas propostas para representar de forma eficaz imagens digitais em dimensões menores, extraindo características relacionadas a cor, textura e forma (TIAN et al., 2013). No contexto de extração de características, os coeficientes *curvelet* são exemplos de características extraídas de imagens por meio da aplicação da transformada *curvelet* e buscam representar, no domínio da frequência, a imagem em diferentes ângulos e escalas, podendo então serem utilizados como descritores da imagem em questão. Os coeficientes foram propostos primeiramente em Candes e Donoho (2000) e desde então têm sido explorados em diferentes âmbitos como marcas d'água em diferentes faixas de frequência de imagens (LEUNG; CHENG; CHENG, 2009), algoritmos de compressão de imagens (LI; YANG; JIAO, 2010) e características utilizadas no processo de classificação de diferentes contextos de imagens (ZHANG et al., 2013; ELTOUKHY; GARDEZI; FAYE, 2014; BRUNO et al., 2016; RIBEIRO et al., 2019; YASIRAN et al., 2021; GÖRGEL, 2021).

A classificação, outra etapa presente no processo de análise de imagens, também tem sido amplamente explorada na literatura, com métodos como *Support-vector machines* (SVM) (HEARST et al., 1998), *Artificial Neural Networks* (ANN) (HOPFIELD, 1988) e *Decision-Tree* (DT) (MYLES et al., 2004). No contexto das ANN, redes neurais artificiais que buscam resolver problemas computacionais envolvendo sistemas biológicos (HOPFIELD, 1988), as propostas exploram várias abordagens por meio da estratégia de aprendizado profundo, ramo a qual pertencem as *Convolutional Neural Networks* (CNN). Redes Neurais Convolucionais já conhecidas, como *SqueezeNet* (IANDOLA et al., 2016), VGG (SIMONYAN; ZISSERMAN, 2014) e *ResNet* (HE et al., 2016) são utilizadas em diversos trabalhos que propõem modelos para classificação de imagens médicas (GUO; YANG, 2018; SENGUPTA et al., 2019; WU; SHEN; HENGEL, 2019; UCAR; KORKMAZ, 2020), como comparação ou parte dos *frameworks* de processamento de imagens proposto pelos autores.

Ainda no contexto de classificação, uma técnica que surgiu com objetivo de melhorar a performance de classificadores e que possui diversas abordagens propostas recentemente na literatura, como mostrado por Zhuang et al. (2020), chamada de *transfer learning*, é definida pelo processo de transferência de conhecimento adquirido pelo classificador em um contexto diferente aplicado ao contexto desejado. A transferência de conhecimento possibilita a aplicação de redes profundas, como as CNN, em contextos em que uma CNN não produz bons resultados devido ao tamanho e número de camadas da rede, como em casos de poucos dados disponíveis para treinamento do modelo (RIBANI; MARENGONI, 2019). Deste modo, aplicando os conceitos de *curvelets*, CNNs e transferência de conhecimento, é possível criar modelos para classificação de imagens histológicas mesmo com poucos dados disponíveis para treino.

1.1 Justificativas e Motivação

A transformada *curvelet* é utilizada na literatura no processo de extração de características, como por exemplo na classificação de imagens histológicas de câncer de próstata (LIN et al., 2015), detecção de úlceras (EID et al., 2013), mamografias para identificar câncer de mama (SARASWATHI; DHARANI; SRINIVASAN, 2016) e até em conjunto com redes neurais no processo de classificação de cérebros saudáveis como observado em Nayak et al. (2017).

Os trabalhos obtiveram bons resultados combinando *curvelets* com outras técnicas de extração de características, por exemplo, técnicas de redução do número de características após aplicação da transformada mas não com o uso associado por meio de CNN, etc. Neste cenário, foi identificada a necessidade de observar qual a contribuição dos coeficientes *curvelet* extraídos de imagens histológicas no processo de classificação de imagens utilizando CNN, assim como quais são os melhores cenários observados quando adotadas diferentes combinações entre imagens histológicas e representações *curvelet* nos conjuntos de treinamento e testes dos modelos de CNN.

1.2 Objetivos

Neste projeto é proposto um método que explora a associação de sub-imagens *curvelet* e redes neurais convolucionais para classificação de imagens histológicas, a fim de verificar se a combinação imagens histológicas e suas representações *curvelets* podem melhorar as discriminações entre diferentes tipos de classes resultando em aumento na taxa de distinção do modelo na etapa de classificação das imagens. Detalhadamente, os objetivos são:

1. Extrair características de imagens histológicas por meio de coeficientes *curvelet* utilizando uma quantidade arbitrária de escalas e ângulos na aplicação da transformada em questão;
2. Implementar e aplicar transferência de conhecimento em um modelo de rede neural convolucional para classificação em diferentes classes de diferentes bases de imagens histológicas;
3. Aplicação dos modelos em diferentes bases de imagens histológicas;
4. Observar o comportamento da distinção de cada combinação quando sub-imagens *curvelet* são adicionadas ao conjunto de imagens histológicas.

1.3 Organização do trabalho

No capítulo 2 são apresentados os conceitos aplicados no desenvolvimento do projeto, como extração de características de imagens, a transformada *curvelet* e os coeficientes resultantes da aplicação da transformada, redes neurais convolucionais, o processo de transferência de conhecimento e o tipo de imagem utilizada no projeto. Ainda no capítulo 2, são exemplificados trabalhos relacionados às técnicas e conceitos apresentados na seção de fundamentação teórica, sendo eles trabalhos relacionados a

aplicação da transformada *curvelet* e uso dos coeficientes *curvelet* com foco em imagens médicas e uso de redes neurais convolucionais no processamento de imagens médicas. A metodologia utilizada no projeto é apresentada no capítulo 3, composto pela visão geral do método e dos detalhes de implementação dos algoritmos utilizados. Os resultados dos experimentos realizados e a discussão sobre os mesmos estão no capítulo 4 e as conclusões no capítulo 5.

Capítulo 2

Referencial Teórico

Neste capítulo são apresentados os conceitos teóricos que serviram como base para desenvolvimento do trabalho e trabalhos relacionados presentes na literatura. Na seção 2.1 são descritos os conceitos de extração de características, coeficientes *curvelet*, redes neurais, *transfer learning* e imagens histológicas. Alguns trabalhos relevantes relacionados a redes neurais convolucionais e *curvelets* são apresentados na seção 2.2.

2.1 Fundamentação Teórica

Nesta seção são apresentados os conceitos utilizados no desenvolvimento do trabalho, assim como as técnicas e modelos utilizados para implementação dos experimentos propostos e também o tipo de imagens utilizadas. Na subseção 2.1.1 é abordado o tema extração de características, exemplos e sua importância no processamento de imagens. Na subseção 2.1.2 é abordada a transformada rápida Curvelet, uma das técnicas utilizadas para extração de características de imagens. Na subseção 2.1.3 são apresentadas as redes neurais artificiais (ANN) e a área de *Deep Learning*. A subseção 2.1.4 expõe detalhes de Redes Neurais Convolucionais (CNN) e as características da estrutura das camadas de uma CNN. Na subseção 2.1.5 é introduzido o conceito de transferência de conhecimento e as vantagens desse tipo de abordagem. Na subseção

2.1.6 são apresentadas as Redes Neurais Residuais (ResNet), com foco na ResNet50, modelo utilizado no trabalho. Por fim, na subseção 2.1.7 são apresentados alguns conceitos sobre imagens histológicas, tipo de imagem médica utilizada no trabalho.

2.1.1 Extração de Características

Outro modo de representar imagens que não os valores de *pixels* que a compõem é por meio de características, sendo esse modo interessante do ponto de vista de construção de classificadores. Características são descritores ou métricas que são extraídas da imagem e são capazes de representá-la de maneira adequada, buscando aumentar a eficiência do armazenamento e processamento de informação, por representarem a imagem com dimensão reduzida (GUYON et al., 2008).

Extrair características úteis de uma cena é uma das tarefas essenciais na análise de dados multimídia, como classificação e recuperação (WANG et al., 2014). As características extraídas de uma imagem podem ser relacionadas a qualquer aspecto da imagem como cor, textura e forma. Um exemplo de métrica são os coeficientes gerados aplicando a transformada *curvelet* a uma imagem, que se tratam de características da imagem que buscam representar textura (CANDES; DONOHO, 2000).

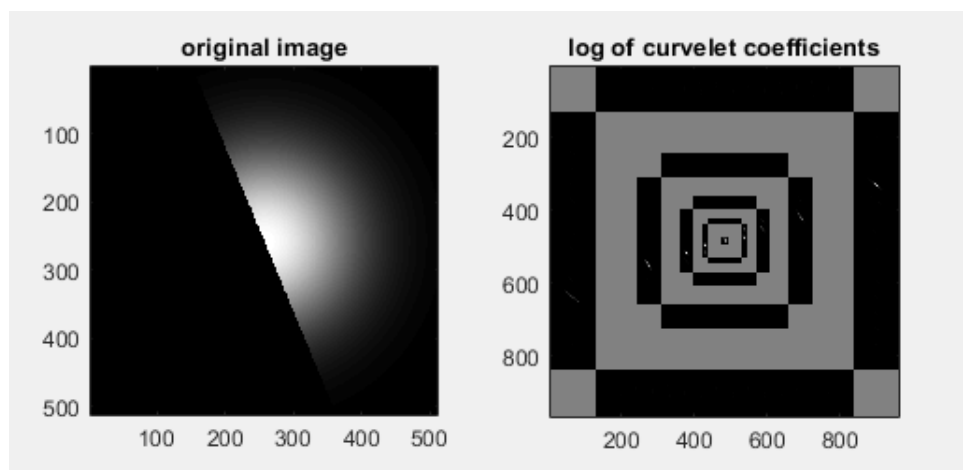
2.1.2 Transformada Curvelet

A primeira transformada *curvelet* foi desenvolvida em 1999 e publicada em Candes e Donoho (2000) numa tentativa de superar limitações inerentes às representações multi-escala tradicionais, como as *wavelets* (CANDES et al., 2006). As *curvelets* surgiram com objetivo de melhor representar bordas de objetos em imagens e desde então a técnica foi aperfeiçoada e a transformada *curvelet* descrita é a de segunda geração.

Com o uso de variações em ângulo e escala, a transformada busca representar, no domínio da frequência, pontos de singularidade em imagens, como pontos de descon-

tinuidade, indicando bordas de objetos, por exemplo. Após a primeira publicação, a transformada *curvelet* já evoluiu para outros domínios e implementações. Na Figura 2.1 é mostrada a representação dos coeficientes para dada imagem original.

Figura 2.1: Representação visual dos coeficientes *curvelet* de uma imagem.




Fonte: Elaborado pelo autor.

2.1.3 Transformada Rápida Discreta Curvelet via Envelopamento

A transformada rápida discreta *curvelet* foi publicada em Candes et al. (2006) e tem duas implementações, uma utilizando transformadas rápidas Fourier não igualmente espaçadas e outra utilizando envelopamento, que é a implementação utilizada neste trabalho, que segue o praticado em Ribeiro et al. (2019). A implementação utilizando envelopamento recebe como entrada uma imagem 2D e é escaneada em áreas, gerando uma saída composta por um conjunto de coeficientes indexados de acordo com as escalas e ângulos utilizados como parâmetros da transformada (BRUNO et al., 2016). Na Figura 2.2 é representada a técnica de envelopamento para escala quatro e ângulo quatro.

Figura 2.2: Exemplo de sub-imagem gerada a partir dos coeficientes *curvelet* de escala quatro e orientação quatro.



Fonte: Adaptado de Bruno et al. (2016).

2.1.4 Artificial Neural Networks e Deep Learning

As Redes Neurais Artificiais, em inglês *Artificial Neural Networks* (ANN), surgiram como uma técnica de aprendizado de máquina que tinha como objetivo imitar o comportamento do cérebro humano em relação ao processamento de informação, se utilizando de conexões entre um grande número de entidades mais simples estruturalmente, como os neurônios, para processar informações complexas utilizadas como entrada. Constituídas por camadas de neurônios que atuam como funções aritméticas levando em conta os pesos de conexões entre esses neurônios, bias e funções de ativação, as redes neurais artificiais consistem de uma camada para entrada de dados, camadas internas por onde a informação passa e uma camada de saída (ABRAHAM, 2005). A saída de uma camada é usada como entrada da próxima.

Quando uma rede neural é treinada, os pesos atribuídos às ligações entre os neurônios determinam a importância dada a cada característica presente nos dados de entrada. O ajuste desses pesos faz com que a rede, ao final do treinamento, seja capaz de identificar padrões nos dados de entrada com altos níveis de acurácia. Técnicas convencionais de aprendizado de máquina são limitadas em sua habilidade de processar dados naturais como *pixels* de uma imagem, por exemplo (LECUN; BENGIO;

HINTON, 2015).

Uma evolução das redes neurais convencionais são redes que aplicam conceitos de *Deep Learning*, que permitem descobrir estruturas complexas presentes em grandes conjuntos de dados utilizando do algoritmo de *backpropagation* (ROBERT et al., 1989) para indicar à própria rede como ela deve ajustar seus parâmetros internos para se adequar melhor aos dados de entrada. A introdução de redes neurais profundas ajuda a solucionar problemas muito mais complexos utilizando redes neurais mas também introduz alguns desafios na implementação da solução. Apesar dos benefícios citados, redes neurais profundas sofrem com problemas como dissipação de gradiente e explosão de gradiente, problemas relacionados justamente a quantidade de camadas da rede, tornando assim as redes neurais profundas mais difíceis de treinar que uma rede convencional.

2.1.5 Redes Neurais Convolucionais

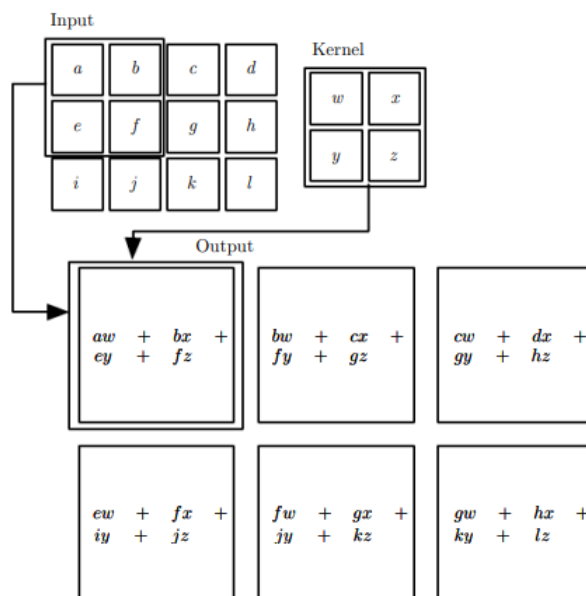
Uma das arquiteturas derivadas de *Deep Learning* é a Rede Neural Convolutiva (CNN). Esse tipo de rede aplica filtros aos dados recebidos pela camada convolutiva, com o objetivo de computar diferentes características presentes nos dados de entrada (GU et al., 2018). Na mesma rede são então aplicadas outras técnicas para acentuar e selecionar essas características e auxiliar no resultado final.

Redes Neurais classificadas como convolucionais apresentam estrutura bem característica, sendo formadas por camadas distintas que se repetem e se intercalam com outras. Alguns exemplos de camadas presentes em CNN são a camada convolutiva, camada de *pooling*, camada totalmente conectada, etc. Além das camadas, algumas funções são bem conhecidas por serem aplicadas aos dados de saída de camadas de uma CNN, chamadas de funções de ativação (SHARMA; SHARMA; ATHAIYA, 2017), sendo algumas delas ReLU, Sigmoid, Softmax, etc.

2.1.6 Camada Convolutiva

A camada convolutiva de uma CNN recebe esse nome pois realiza nos dados uma operação de convolução que, no caso das CNN para processamento de imagens, por exemplo, é realizada entre duas matrizes. Uma das matrizes é a matriz do filtro a ser aplicado na imagem e a outra é uma área da imagem de mesmo tamanho da matriz do filtro. A operação de convolução é realizada por toda a imagem, com incrementos de um pixel por vez, tanto na largura quanto na altura, do canto superior esquerdo até o canto inferior direito da imagem (WU, 2017). Assim que a área da imagem é selecionada, é realizada então a soma dos produtos de cada posição da matriz que forma o filtro com a posição correspondente da região da imagem. Em cada camada convolutiva da CNN são aplicados diversos filtros na tentativa de extrair diferentes características da imagem. Na Figura 2.3 é descrito o cálculo realizado na operação de convolução.

Figura 2.3: Exemplo de operação de convolução mostrando a área, filtro e resultado.




Fonte: (GOODFELLOW; BENGIO; COURVILLE, 2016).

2.1.7 Camada de Pooling

As camadas de *pooling* estão presentes nas CNN para realizar uma redução na quantidade de pontos da imagem recebida da camada anterior, reduzindo o número de conexões entre as camadas convolucionais (GU et al., 2018). Essa operação seleciona uma área da imagem e aplica uma função que retorna apenas um valor que represente toda a área, reduzindo assim as dimensões da imagem. Um exemplo de função utilizada é a *max pooling*, muito utilizada para realizar *pooling* em CNN, que compara todos os valores da área e retorna o maior para representar a área, como ilustrado na Figura 2.4. A área da imagem selecionada para *pooling* varia mas o tamanho 2x2 é muito utilizado, o que faz com que a imagem de saída tenha metade da altura e largura da imagem de entrada. Outra função utilizada para *pooling* é o *average pooling*, função essa que calcula a média dos valores da área e retorna essa média para representar a área.

Figura 2.4: Exemplo de uma operação de *max pooling*.



Fonte: (GOODFELLOW; BENGIO; COURVILLE, 2016).

2.1.8 Funções de ativação

As funções de ativação são aplicadas entre a saída de uma camada e a entrada da próxima, ou seja, ela que determina o valor que a próxima camada receberá como entrada e, se aplicada corretamente, pode aumentar significativamente a performance de uma CNN (GU et al., 2018). Muitas vezes as funções de ativação são necessárias para manter as entradas das próximas camadas dentro de um limite controlado, caso necessário, e também para introduzir característica não linear aos dados de saída da camada,

já que as operações realizadas nas camadas são lineares, por exemplo, multiplicar o valor recebido da camada anterior com o peso da conexão com o neurônio anterior e somar um bias.

Uma das funções de ativação mais utilizadas em redes neurais convolucionais é a Unidade Linear Retificada (ReLU), que é amplamente utilizada na saída das camadas convolucionais. A função ReLU, como é comumente chamada, apenas retorna o maior valor entre zero e o valor de entrada, agindo como um filtro de valores negativos na imagem de saída. Por se tratar de apenas uma comparação, a função ReLU possui baixo gasto computacional para ser realizada, performando melhor que outras funções de ativação (SHARMA; SHARMA; ATHAIYA, 2017).

$$ReLU(x) = \max(0, x) \quad (2.1)$$

Outra função de ativação, a mais utilizada atualmente em CNNs, é a função Sigmoid. Função não-linear que varia sua saída entre zero e um (SHARMA; SHARMA; ATHAIYA, 2017), a sigmoide é muito utilizada em situações em que é desejada que a saída da CNN seja uma probabilidade, como nos casos de previsão, pois se mantém nesse intervalo análogo ao intervalo de probabilidade.

$$S(x) = \frac{1}{1 + \exp(-x)} = \frac{\exp(x)}{\exp(x) + 1} \quad (2.2)$$

A função de ativação Softmax também é do tipo sigmoide, ou seja, também faz uso da exponencial para normalizar o valor de entrada num intervalo conhecido, entre zero e um. Se tratando de uma combinação entre múltiplas Sigmoides (SHARMA; SHARMA; ATHAIYA, 2017) e também muito utilizada em CNN, a Softmax entrega o resultado num formato de probabilidade, conveniente para situações de classificação

de imagens em classes.

$$\text{Softmax}(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)} \quad (2.3)$$

2.1.9 Transfer Learning


O treinamento de uma rede neural convolucional requer um grande número de dados de entrada. A transferência de conhecimento é um modo eficiente de utilizar representações de imagens aprendidas utilizando CNN e grandes bancos de imagens, em domínios em que há limite de dados disponíveis para realização de treinamento (ZHOU; GREENSPAN; SHEN, 2017).

Em *Deep Learning*, o processo de *transfer learning* é a melhoria no processo de aprendizado de uma nova tarefa a partir da transferência de conhecimento previamente obtido em outra tarefa relacionada (TORREY; SHAVLIK, 2010). Usando camadas do modelo pré-treinado em conjunto com camadas a serem treinadas com a base do problema que se tem interesse, é possível obter melhoras na performance do modelo mais rapidamente.

2.1.10 ResNet50

A Resnet50, ou *Residual Neural Network*, é um modelo de CNN proposto em He et al. (2016) que utiliza técnicas para minimizar problemas conhecidos das redes neurais profundas, como a dificuldade de treinamento e a estagnação, ou até queda, da acurácia da classificação. Com as técnicas utilizadas nas ResNet, é possível criar redes neurais convolucionais profundas com grandes números de camadas, como exemplificado na Figura 2.5, sem que isso signifique perda de performance da CNN.


Figura 2.5: Exemplo de Rede Neural Residual com 34 camadas.



Fonte: (HE et al., 2016).

O conceito utilizado nas redes neurais residuais é o de conhecimento residual, que se trata de conectar diretamente saídas de um camada x com a entrada de uma camada $x+3$, por exemplo, além das conexões sequenciais entre camadas. Quando essa conexão é criada, ela introduz um resíduo de conhecimento da camada x na camada $x+3$, diminuindo então o problema da queda de acurácia causada pela dissipação do gradiente, problema conhecido das redes neurais profundas. Essas conexões, chamadas de *skip connections*, representadas na Figura 2.6 são criadas ao longo de toda a rede, pulando camadas e formando blocos residuais.

Figura 2.6: Exemplo de bloco residual utilizado nas redes neurais residuais, onde a *skip connection* acontece.




Fonte: (HE et al., 2016).

Um dos modelos propostos de redes residuais é a ResNet50, que se trata de uma variação da rede, mas que possui 50 camadas. O modelo da ResNet50, representado na Figura 2.7, foi proposto com uma camada convolucional inicial seguida de um *max pooling*, 16 blocos residuais constituídos de três camadas convolucionais cada (intercaladas com funções ReLU) e um *average pooling* seguido de uma camada totalmente

conectada onde é aplicado o Softmax, resultando em 50 camadas.

Figura 2.7: Arquitetura da Resnet50, rede neural residual.



Fonte: Adaptado de Mahmood et al. (2020).


Quando se deseja aplicar transferência de conhecimento em uma rede como a ResNet, uma das ideias é utilizar toda a estrutura convolucional da rede pré-treinada em outro problema, como é o caso em He et al. (2016), trabalho que propôs o modelo, em que a rede é treinada utilizando a base de dados ImageNet e é capaz de classificar imagens em mil categorias diferentes.

Utilizando então a estrutura convolucional da rede juntamente com uma adaptação da nova camada totalmente conectada no fim, é possível tirar proveito desses pesos pré-calculados e ajustar apenas os pesos da camada totalmente conectada.

2.1.11 Imagens Histológicas

Histologia é um ramo da anatomia que estuda tecidos de organismos vivos (GARTNER; HIATT, 2006). A histologia permite distinguir entre tecido normal, lesões benignas e malignas para auxiliar no processo de avaliação. Colorir esse tecido utilizando Hematoxilina e Eosina (H&E) é uma das práticas mais comuns, em que o citoplasma presente apresenta cor rosa e núcleos de células apresentam cor roxa, assim como outras estruturas que interesse ao estudo (ARAÚJO et al., 2017). Exemplos de imagens histológicas estão na Figura 2.8, representando casos de câncer colorretal benigno (a) e maligno (b).

Figura 2.8: Exemplo de imagens histológicas de câncer colorretal benigno (a) e maligno (b).



Fonte: (SIRINUKUNWATTANA et al., 2017).

2.2 Trabalhos Relacionados

Com base nas técnicas utilizadas na elaboração dos experimentos deste trabalho, esta seção tem como objetivo apresentar trabalhos relacionados a essas técnicas, dando foco em trabalhos envolvendo imagens histológicas, por se tratar do tipo de imagem utilizado neste trabalho. Na subseção 2.2.1 são apresentados os trabalhos relacionados à transformada *curvelet* e suas diferentes aplicações e na subseção 2.2.2 são apresentados os trabalhos relacionados ao uso de redes neurais convolucionais no âmbito de imagens médicas.

2.2.1 Transformada Curvelet

Após sua proposição em Candes e Donoho (2000), vários estudos foram desenvolvidos acerca da eficiência da transformada *curvelet* para representar texturas em imagens e posterior classificação, dentre elas imagens histológicas. Os autores Eltoukhy, Faye e Samir (2010a, 2010b, 2010c), com uma série de estudos, documentaram sobre a utilização de coeficientes *curvelet* em auxílio de diagnóstico a câncer de mama.

Em Eltoukhy, Faye e Samir (2010a), que é proposta a abordagem utilizando mais escalas e o mesmo classificador supervisionado baseado em distância euclidiana, os experimentos indicaram que os coeficientes *curvelet* são descritores promissores para uso em auxílio a diagnóstico em mamografias digitais. Em Eltoukhy, Faye e Samir

(2010b), onde comparam o desempenho dos coeficientes *curvelet* ao desempenho dos coeficientes *wavelet*, usando um sistema de classificação supervisionado baseado em distância euclidiana, em que os resultados sugeriram que *curvelets* apresentam aumento estatisticamente relevante em comparação com *wavelets*. Ainda em 2010, em Eltoukhy, Faye e Samir (2010c), os autores expõem em detalhes a etapa de obtenção e seleção dos coeficientes *curvelet* para uso no método proposto nos outros trabalhos.

Os autores em Zhang et al. (2013) exploram o potencial da transformada *curvelet* em conjunto com análise de textura utilizando *Local Binary Pattern* (LBP) e *Gray Level Co-occurrence Matrix* (GLCM), posteriormente utilizando um classificador supervisionado composto por duas fases, com objetivo de diminuir o número de classificações equivocadas, dando a opção de rejeitar imagens na primeira fase e utilizá-las como entrada para a segunda fase, aumentando assim a confiança na classificação. Neste trabalho o uso dos coeficientes *curvelet* juntamente com outros métodos de extração de características de textura se provou eficaz na etapa de classificação de imagens.

Os autores em Liu et al. (2016) expõem um estudo realizado com imagens capturadas por *Wireless capsule endoscopy* (WCE), método não-invasivo utilizado para identificar doenças em todo o trato gastrointestinal, em pacientes com suspeita de tumores. No trabalho é proposto um conjunto de características obtidas da combinação das técnicas de transformada *curvelet* e dimensão fractal, onde as características mais relevantes são selecionadas por meio de algoritmos genéticos e são utilizadas na fase de classificação que faz uso de *Support-vector machine* (SVM) para classificar as imagens. Com a participação de 105 pacientes no estudo com WCE, 89 vídeos foram capturados e submetidos ao método proposto, detectando 15 situações de presença de câncer de intestino delgado. Com uma acurácia de 97,3%, o método foi comparado com outros métodos de classificação e foi demonstrado que o método proposto, utilizando transformada *curvelet*, dimensão fractal e algoritmos genéticos tem melhor

desempenho na classificação de imagens clínicas reais.

O método proposto por Bruno et al. (2016) para classificação de câncer de mama que implementa uma associação entre transformada curvelet e *Local Binary Pattern* (LBP) na fase de extração de características, consistindo de aplicar a transformada curvelet multi-escala nas imagens de entrada e aplicar LBP às sub-imagens obtidas. Para redução do número de atributos gerados pela fase de extração de características, é utilizada a técnica de análise de variância (ANOVA) que seleciona os atributos mais relevantes a serem utilizados na etapa de classificação. Para a etapa de classificação são utilizadas diferentes abordagens conhecidas da literatura, sendo elas: *Decision Tree* (DT), *Random Forest*, *Support-vector machine* (SVM) e classificadores polinomiais (PL), a fim de comparar os resultados entre as diferentes abordagens e também outras abordagens presentes na literatura. O método composto por classificador polinomial obteve acurácia de 100% em um dos *datasets* utilizados, o *UCSB biosegmentation benchmark* (UCSB-BB), composto por imagens histológicas. O método se mostrou mais eficiente quando comparado aos métodos compostos por outros classificadores e também quando comparado a métodos propostos presentes na literatura, o que mostra que o método é útil para utilização em sistemas de apoio a diagnóstico.

Os autores em Ribeiro et al. (2019) propõem um método para classificação de câncer colorretal que associa transformada curvelet com técnicas fractais e descritores de Haralick, duas outras técnicas conhecidas da literatura para extração de características. Para cada imagem de entrada, assim como para todas as sub-imagens que representam os coeficientes gerados pela transformada curvelet, foram extraídas as características de dimensão fractal, lacunaridade, percolação e os descritores Haralick, resultando em um vetor de 1512 atributos para cada imagem de entrada. Levando em consideração a quantidade de atributos obtidos, foi aplicado o algoritmo *ReliefF* com objetivo de ranquear os atributos por ordem de importância. Utilizando o *ranking* obtido do algoritmo *ReliefF* e realizando experimentos utilizando de cinco até 100 características

das mais bem ranqueadas, a fase de classificação consistiu da aplicação de diferentes métodos disponíveis na literatura, sendo eles: *Decision Tree* (DT), *Random Forest*, *Support-vector machine* (SVM), *naive Bayes*, k^* e um método polinomial (PL); e ao final dos experimentos foram selecionados 43 atributos para fazer parte do método final proposto.

Esse estudo obteve resultados interessantes a respeito das *curvelets*, como o fato de que nenhum atributo final faz parte de dimensões fractais ou descritores de Haralick calculados a partir de sub-imagens *curvelet*, o que pode indicar que esse tipo de característica não é relevante no estudo de imagens histológicas. Por outro lado, 40 dos 43 atributos selecionados são lacunaridade e percolação calculados a partir de sub-imagens *curvelet*, o que indica uma associação interessante no estudo de transformada *curvelet*.

2.2.2 Redes Neurais Convolucionais

Com o surgimento da abordagem convolucional houve também um crescimento expressivo da quantidade de trabalhos que sugere soluções para diversos problemas utilizando redes profundas.

No caso do trabalho dos autores em Mazo et al. (2018), é proposto o uso de um mesmo modelo de CNN na classificação de seis diferentes tecidos e órgãos do corpo humano a partir de imagens histológicas, sendo eles: músculo cardíaco, tecido conjuntivo laxo (veias, artérias e coração), músculo liso da artéria muscular, veias grandes, artéria elástica e regiões claras. O processo de *transfer learning* é realizado nos modelos ResNet, VGG19, VGG16 e *Inception*, modelos de CNN conhecidos na literatura. Após realização dos testes e comparação dos modelos entre si, o modelo ResNet foi selecionado para prosseguir como modelo referência na próxima etapa de testes pois teve melhor precisão de modo geral, no valor de 81,9%.

Por se tratar de uma abordagem de transferência de conhecimento, o teste realizado

na sequência teve como objetivo comparar o desempenho da ResNet com um modelo de rede neural sem treinamento prévio, treinado desde o início para o problema abordado no trabalho e chamada pelos autores de HistoNet. A HistoNet obteve valores maiores de precisão em tecido elástico (98,4%) e tecido do coração (92,3%), enquanto a ResNet obteve melhores valores nas outras quatro classes (71,2%, 82%, 57,8% e 95,5%), resultando em um melhor desempenho no geral, de 81,9%.

Como última etapa de testes, o modelo ResNet foi comparado com uma abordagem de estado-da-arte para modelos supervisionados atuais, um modelo de classificação que utiliza *Support vector machine* (SVM) com extração de características por meio de descritores LBP (*Local Binary Patterns*). Para todas as classes de tecidos e órgãos a ResNet apresentou melhores resultados que o modelo supervisionado utilizando SVM, com maior diferença entre os modelos observada na classe de tecido muscular, que foi de 71,2% de precisão para a HistoResNet e 44,2% de precisão para o modelo SVM. Entre as conclusões dos autores estão a importância e eficácia da aplicação da técnica de transferência de conhecimento e o potencial das redes neurais convolucionais na classificação automática de tipos de tecidos.

Os autores em Fu et al. (2018) descrevem os desafios da segmentação de imagens histológicas, devido a problemas como a complexidade e alto grau de variação das características das imagens. No trabalho é proposto um modelo de CNN voltado para a segmentação de imagens histológicas de tecido cardíaco que separa a imagem em áreas de fibrose, miócitos e fundo. A CNN proposta é composta por 11 camadas convolucionais, com nove delas consistindo de filtros 3x3 com 64 canais, função ReLU e normalização dos dados de saída e as duas últimas de filtros 1x1 de três canais, função ReLU e normalização dos dados de saída. Ao final, utilizando as três imagens geradas como saída da CNN, é formada a imagem final segmentada, por meio de comparação de maior valor das três imagens para cada pixel do mapa final.

O modelo de CNN foi comparado com as técnicas conhecidas de segmentação de

imagem *k-means RGB*, *k-means Lab*, U-Net e FCN-8, utilizando métricas também conhecidas de cálculo de performance em técnicas de segmentação, sendo elas: *Dice similarity coefficient* (DSC) e *Intersection over union* (IoU), métricas com valores entre 0 e 1, com números maiores indicando melhor eficácia. Na comparação o modelo proposto apresenta maior DSC e IoU em todos os testes em comparação com os modelos prévios, revelando também uma maior eficiência no cálculo, diminuindo em até 60% a quantidade de operações necessárias para toda a operação de segmentação quando comparada aos outros modelos.

O estudo realizado em Yoon et al. (2019) explora a CNN *VGG ConvNet*, uma CNN já conhecida e utilizada para classificação de imagens, propondo variações e comparando-as entre elas no problema de classificação de câncer colorretal. Foram propostos cinco modelos modificados de *VGG ConvNet*, com quantidade de camadas variando de onze a dezenove. Nos testes realizados entre as redes, foi observado aumento da acurácia conforme o número de camadas convolucionais aumentou, com a variante que possui 19 camadas apresentando maior acurácia, 94,3%, com um número 14 de *epochs*.

Os autores em Alinsaif e Lang (2020) propõem o uso de CNN na etapa de extração de características do processamento de imagem, e não na etapa de classificação, onde é comumente aplicada. Chamados no trabalho de *Deep Features*, os descritores derivados da imagem de entrada são captados fazendo uso de quatro redes neurais conhecidas utilizando técnicas de *transfer learning*, sendo elas *SqueezeNet-v1.1*, *MobileNet-v2*, *ResNet-18* e *DenseNet-201*, onde os dados de saída da camada mais profunda da rede antes da camada de classificação são capturados. O processo de extração de características gera um total de 4712 descritores que são então utilizados como entrada de um algoritmo de redução de dimensão chamado *Infinite Latent Feature Selection* (ILFS) (ROFFO et al., 2017) com objetivo de ranquear e selecionar os descritores mais relevantes para o problema utilizando uma abordagem baseada

em grafos para representar relevância dos descritores. Por fim, um modelo SVM é treinado utilizando os descritores melhor ranqueados e esse modelo treinado é comparado com diversos outros modelos, sendo eles o mesmo modelo SVM treinado com todos os descritores, os modelos de CNN pré-treinados e utilizando *transfer learning* e os modelos *ResNet-18* e *SqueezeNet* otimizados por meio de *fine-tuning*. Dentre as conclusões dos autores, tem-se a constatação da utilidade dos modelos de CNN como extratores de característica.

2.2.3 Considerações Sobre os Trabalhos Relacionados

Neste capítulo foram apresentados trabalhos que utilizaram CNNs e também coeficientes *curvelet* no processo de classificação de imagens médicas. Os coeficientes *curvelet* mostraram bons resultados nos estudos mencionados, apesar de aplicados em vários contextos e disposições diferentes. Um resultado importante sobre *curvelets* é a melhora dos resultados em relação as *wavelets* em Eltoukhy, Faye e Samir (2010b), que foi um dos objetivos da proposição inicial das *curvelets* por Candes e Donoho (2000). Em Zhang et al. (2013) e Liu et al. (2016) os coeficientes *curvelet* representaram bons resultados quando associados a outras características extraídas das imagens, contribuindo para aumento da acurácia nos trabalhos. Outro contexto em que os coeficientes apresentaram resultados promissores foi quando métricas e descritores conhecidos da literatura, como *Local Binary Pattern* (BRUNO et al., 2016), lacunaridade e percolação (RIBEIRO et al., 2019), foram extraídos das sub-imagens geradas a partir dos coeficientes, mostrando mais uma área de uso possível para coeficientes *curvelet*.

Assim como com os coeficientes *curvelet*, os trabalhos apresentados sobre CNN utilizam a rede neural em vários contextos e etapas diferentes do processo de classificação de imagens, como em Fu et al. (2018) em que uma CNN é proposta para segmentar imagens e os resultados apresentam aumento na eficácia e nos índices relevantes ao contexto de segmentação de imagens quando comparada a algoritmos já

estabelecidos na literatura. Com um caso de uso mais comum, Mazo et al. (2018) propõe uma CNN para classificação de diferentes tecidos do corpo humano e, nesse caso, os resultados são relevantes pois na comparação entre outros modelos de CNN, a ResNet foi o modelo que foi utilizado como referência por ter obtido melhores resultados. Outro contexto em que CNN foi utilizada nos trabalhos relacionados é na extração de características, produzindo as *deep features*, como descrevem os autores em Alinsaif e Lang (2020). A CNN gera diversos descritores como saída que depois são submetidos a outras técnicas de classificação de imagens, mostrando mais um caso de uso possível para CNN.

Capítulo 3


Metodologia

Neste capítulo é apresentado o método proposto com as especificações da transformada *curvelet*, associações de imagens e as métricas utilizadas para avaliar os resultados. Na seção 3.1 são apresentadas as características das cinco bases de imagens histológicas que foram utilizadas nos experimentos. Na seção 3.2 são apresentadas as informações sobre as ferramentas utilizadas para a implementação e execução do trabalho. As métricas definidas para avaliar a proposta são descritas na seção 3.3. Na seção 3.4 é descrita a estruturação da proposta e as combinações de imagens foram detalhadas na seção 3.5.

3.1 Bases de imagens

Para realizar os experimentos, foram utilizados cinco *datasets* de imagens histológicas. Cada *dataset* é formado por imagens histológicas H&E representativas de diferentes classes. O primeiro *dataset*, definido por Sirinukunwattana et al. (2017), é composto por 165 imagens de tecido colorretal (CR), dividido em dois grupos: tumores benignos (74) e tumores malignos (91). Na Figura 3.1 são ilustradas as duas diferentes classes do *dataset*.


Figura 3.1: Exemplo de imagens histológicas de tumor colorretal benigno (a) e maligno (b).



Fonte: (SIRINUKUNWATTANA et al., 2017).

O segundo *dataset*, disponibilizado pelo *National Cancer Institute* e *National Institute on Aging* (SHAMIR et al., 2008), é composto por imagens de três classes de Linfomas Não-Hodgkin (NHL): Linfoma de células do manto (MCL) com 122 imagens, Linfoma folicular (FL) com 139 imagens e Leucemia linfocítica crônica (CLL) com 113 imagens, totalizando 374 imagens. Na Figura 3.2 são ilustradas cada uma das classes de Linfoma Não-Hodgkin presentes no *dataset*.


Figura 3.2: Exemplo de imagens de linfoma não-Hodgkin do tipo CLL (a), FL (b) e MCL (c).



Fonte: *National Cancer Institute* e *National Institute on Aging*.

O terceiro *dataset* utilizado nos experimentos (UCSB) é composto por 58 imagens de tumores em tecido mamário. As amostras foram divididas em benignas (32) e malignas (26), providas pelo *Center of Bio-Image Informatics* da *University of California, Santa Barbara* (GELASCA et al., 2008). Exemplos das classes são ilustrados na Figura 3.3.


Figura 3.3: Exemplo de imagens histológicas de câncer de mama benigno (a) e maligno (b).



Fonte: *Center of Bio-Image Informatics, University of California, Santa Barbara.*

Os últimos dois *datasets* foram disponibilizados pelo *Atlas of Gene Expression in Mouse Aging Project (AGEMAP)* (ZAHN et al., 2007) e são compostos por 265 imagens de tecido do fígado de ratos. No primeiro conjunto (LG), as imagens foram divididas em dois diferentes gêneros de ratos, masculino com 150 amostras e feminino com 115 amostras. Exemplos de imagens de cada uma das classes é mostrado na Figura 3.4.

Figura 3.4: Exemplos de imagens de tecido do fígado de ratos de gênero masculino (a) e feminino (b).




Fonte: (AGEMAP).

O segundo *dataset* disponibilizado pelo AGEMAP é composto por 528 imagens de tecido do fígado (LA). O conjunto LA foi dividido em quatro classes que representam a idade dos ratos dos quais as imagens se originam, sendo um mês de idade (100), seis meses (115), 16 meses (162) e 24 meses (151). Na Figura 3.5 são mostradas imagens

dos quatro diferentes grupos.

Um resumo das principais informações sobre cada *dataset* está na Tabela 3.1, com destaque para os totais de classes, imagens e as dimensões.

Figura 3.5: Exemplo de imagens de tecido do fígado de ratos com um mês de idade (a), seis meses (b), 16 meses (c) e 24 meses (d).



Fonte: (AGEMAP).

Tabela 3.1: Informações sobre os *datasets* utilizados neste trabalho.

Base	Descrição	Classes	Imagens	Dimensões (em pixels)
CR	Tumor colorretal	2	165 (74/91)	$589 \times 453 \times 775 \times 522$
LA	Tecido do fígado	4	528 (100/115/162/151)	417×312
LG	Tecido do fígado	2	265 (150/115)	417×312
NHL	Linfoma Não-Hodgkin	3	374 (113/139/122)	1388×1040
UCSB	Tumor mamário	2	58 (32/26)	896×768

Fonte: Elaborado pelo autor.

3.2 Ferramentas de Implementação

Todos os testes foram realizados em uma máquina com processador AMD Ryzen 5 3600 3.2GHz, 16GB de memória RAM e uma GeForce RTX 2060 utilizando os pacotes de *software* MATLAB 2019a e Anaconda como ambiente de *Python*, versão 3.9. A extração dos coeficientes *curvelet* foi realizada com a implementação por envelopamento da transformada rápida *curvelet* e que está disponível no pacote MATLAB 2019a, a partir das diretrizes disponíveis em <http://www.curvelet.org/>. A exploração da transformada seguiu as informações discutidas em Ribeiro et al. (2019) e considerou os parâmetros:

- *is_real* com valor 1, parâmetro utilizado para determinar se os coeficientes podem assumir valores complexos;
- *finest* com valor 1, que é responsável por utilizar ou não *curvelets* em níveis mais finos;
- *nbscales* com valor 4, que determina a quantidade de escalas;
- *nbangles_coarse* com valor 8, que determina a quantidade de ângulos utilizados.

O treinamento e testes explorando o modelo pré-treinado da ResNet50 foram realizados a partir dos pacotes *torch* e *torchvision* em *python*. As métricas acurácia, precisão, sensibilidade e F1-score também foram coletadas diretamente do pacote *sklearn* em *python*. O parâmetro utilizado como número de vezes em que os dados de treinamento são percorridos, chamado comumente de número de *epochs*, recebeu valor 30.

3.3 Métricas de avaliação

Para avaliar os resultados conquistados com o método proposto, foram utilizadas diferentes métricas obtidas a partir da relação entre verdadeiros positivos (VP), ver-

dadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN). Os resultados foram coletados ao final da etapa de testes e para cada *epoch*. Nessa seção são apresentadas as formalizações para acurácia, precisão, sensibilidade e F-score, conforme descrito em Rahman et al. (2020), bem como a definição de *loss*.

3.3.1 Acurácia

A acurácia representa a porcentagem de classificações corretas que o modelo apresentou, considerando a soma de verdadeiros positivos (VP) e verdadeiros negativos (VN). O resultado é dividido pelo total de amostras classificadas. A acurácia está definida na Equação 3.1.

$$Acuracia = \frac{VP + VN}{VP + VN + FP + FN} \quad (3.1)$$

Por ser definida como a proporção de verdadeiros positivos e verdadeiros negativos em relação a todos os casos avaliados (BARATLOO et al., 2015), a acurácia é uma porcentagem, variando entre 0 e 100%, com zero sendo o caso em que nenhuma amostra foi classificada corretamente, independente da classe, e 100% sendo o caso em que todas as amostras foram classificadas corretamente para todas as classes disponíveis.

3.3.2 Precisão

A precisão também leva em consideração a quantidade de classificações corretas mas, diferente da acurácia, permite considerar os classificados corretamente de uma determinada classe A em relação a todos os classificados como A. A precisão é a razão entre o número de verdadeiros positivos (VP) e a soma entre verdadeiros positivos e falsos positivos (FP), como ilustrado na Equação 3.2.

$$Precisao = \frac{VP}{VP + FP} \quad (3.2)$$

Em um cenário em que o número de falsos positivos é zero, a precisão tem valor 100%, indicando alta precisão do modelo na classificação da classe verificada.

3.3.3 Sensibilidade

Assim como a precisão, a sensibilidade leva em consideração o número de classificações corretas em determinada classe, mas difere no denominador, em que são somados os verdadeiros positivos (VP) e os falsos negativos (FN). Isso permite contabilizar o total de imagens que realmente pertencem à classe em questão, independente se foram corretamente classificadas ou não. A sensibilidade é definida na Equação 3.3.

$$Sensibilidade = \frac{VP}{VP + FN} \quad (3.3)$$

Por se tratar da proporção de casos classificados corretamente em relação a todos os casos corretos, a sensibilidade é referida em Baratloo et al. (2015) como a habilidade de determinar uma classe corretamente. Com valor também representando porcentagem, a sensibilidade assume valores de zero a 100%.

3.3.4 F-score

A medida F-score representa a média harmônica entre precisão e sensibilidade, permitindo indicar a qualidade do modelo (SASAKI; FELLOW, 2007), conforme definido na Equação 3.4. Assim, caso a precisão seja zero, condição em que nenhuma amostra da classe é classificada corretamente, a medida F1-score também assumirá valor zero. O mesmo raciocínio também se aplica à sensibilidade e, como resultado, a

medida F1-score possui valor mínimo zero e valor máximo 100%.

$$Fscore = 2 \times \frac{Precisao \times Sensibilidade}{Precisao + Sensibilidade} \quad (3.4)$$

3.3.5 Loss

A *loss*, ou perda, de um modelo CNN representa a soma dos erros do modelo no processo de classificação. Como descrito em Janocha e Czarnecki (2017), há diversas funções *loss* utilizadas nas implementações de CNN, como *cross entropy* e *squared log*. Por se tratar de uma soma dos erros de previsão, o valor de *loss* de uma rede pode assumir valores maiores que um e, quanto maior o valor, pior o desempenho do modelo. Assim, neste trabalho foi utilizada a função *cross entropy* para o cálculo da *loss*, que é fornecida diretamente pelos pacotes de ferramentas citados na seção 3.2.

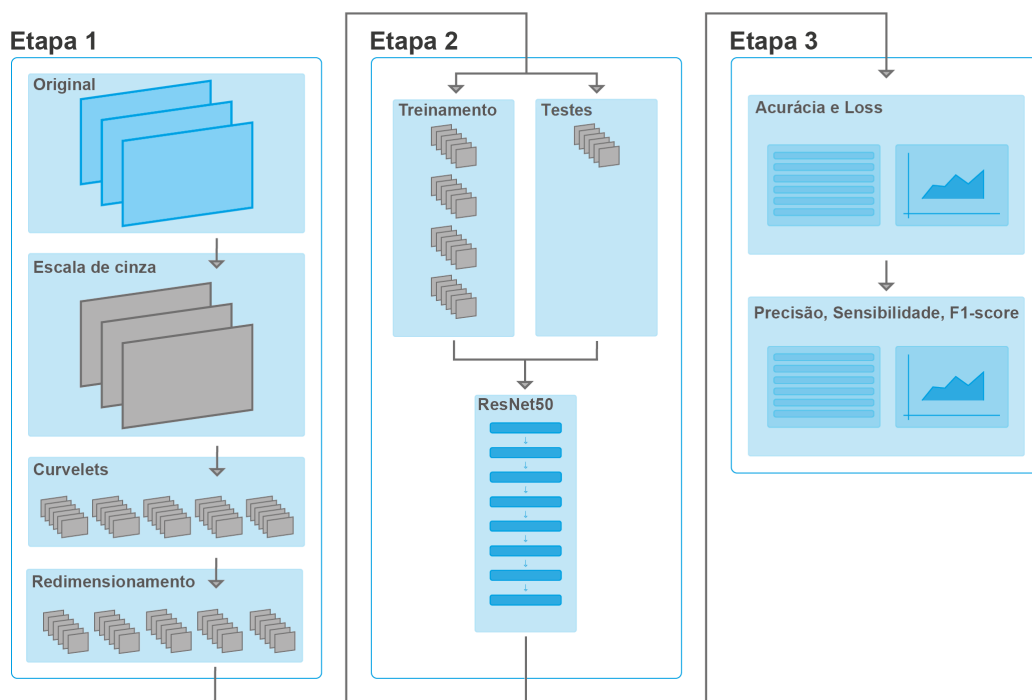
3.3.6 Classificações multi-classe

As métricas indicadas previamente são facilmente aplicadas em contextos envolvendo duas classes, como é o caso de alguns dos *datasets* utilizados neste trabalho. Nos casos em que o total de classes é maior que dois, algumas métricas devem ser ajustadas para considerar esse tipo de situação. Por exemplo, a medida F-score quando calculada em contextos com mais de duas classes, utiliza-se de técnicas de micro-médias e macro-médias (LIPTON; ELKAN; NARYANASWAMY, 2014), em que podem ou não levar em consideração as diferenças nas quantidades de amostras disponíveis em cada classe. O mesmo ocorre para as medidas de precisão e sensibilidade, que precisam ser adequadas para levar em consideração os valores de todas as classes presentes, por exemplo. A variação macro-média utilizada neste trabalho foi obtida pelo mesmo pacote *python sklearn* descrito da seção 3.2.

3.4 Visão Geral do método

O método proposto, representado na Figura 3.6, é composto por três etapas. A etapa 1 é composta pela extração e processamento de características para que sejam utilizadas na etapa seguinte. Primeiramente são extraídos os coeficientes *curvelet* das imagens utilizando a transformada rápida discreta *curvelet* via *wrapping* em sua segunda geração (CANDES et al., 2006) e, posteriormente, as sub-imagens que representam esses coeficientes são submetidas a um redimensionamento, necessário para a etapa 2. Na etapa 2, a CNN *ResNet50* (HE et al., 2016) é adaptada para o contexto de cada uma das bases de dados utilizadas conforme o número de classes disponíveis. Utilizando a estratégia de *transfer learning* (MAZO et al., 2018), a rede neural foi treinada com 80% das primeiras imagens disponíveis no *dataset* e o conjunto remanescente de imagens foi utilizado na fase de teste. Na etapa 3, os resultados produzidos na etapa 2 são avaliados levando em consideração a medida de acurácia.

Figura 3.6: Imagem da visão geral do esquema.



Fonte: Elaborado pelo autor.

3.4.1 Etapa 1 - Extração de Características

A primeira etapa do método proposto é composta por três fases, sendo elas a transformação das imagens para escala de cinza, aplicação da transformada *curvelet* e redimensionamento dessas sub-imagens geradas a partir dos coeficientes obtidos na aplicação da transformada. A primeira fase consiste em transformar as imagens de entrada, originalmente imagens histológicas coloridas com H&E (FISCHER et al., 2008), em imagens em escala de cinza para redução de dimensão da imagem de entrada, passo necessário para aplicação da transformada na fase seguinte, que recebe uma imagem bidimensional como um de seus parâmetros.

A segunda fase consiste em aplicar a transformada rápida discreta *curvelet* (CANDES et al., 2006) nas imagens em escala de cinza com objetivo de extrair os coeficientes *curvelet*, que é um conjunto de descritores utilizado para representar características únicas às imagens originais (CANDES; DONOHO, 2000). Como parâmetros da transformada são passados a imagem em escala de cinza, o número de escalas e o número de ângulos desejados para cálculo dos coeficientes, sendo eles quatro e oito, respectivamente, seguindo o aplicado em Bruno et al. (2016). O número de escalas e ângulos utilizados como parâmetros influencia diretamente na quantidade de sub-imagens obtidas por imagem, que no caso deste trabalho são 41 sub-imagens obtidas para cada imagem em escala de cinza.

A fase final da etapa 1 consiste em redimensionar as sub-imagens calculadas pela transformada na fase anterior para se adequar aos requisitos da rede neural utilizada na etapa seguinte. A *Resnet50* (HE et al., 2016) tem restrições de altura e largura para imagens de entrada, recebendo como entrada apenas imagens 224x224 *pixels*. A quantidade de imagens e sub-imagens *curvelet* obtidas no processo de extração de características para cada grupo está na Tabela 3.2.

Tabela 3.2: Quantidade de imagens H&E e *curvelets* para treinamento e testes.

Base	Classe	Imagens	Histológicas H&E		Sub-imagens Curvelet	
			Treinamento	Teste	Treinamento	Teste
CR	Benigno	74	59	15	2419	615
	Maligno	91	72	19	2952	779
LA	1	100	80	20	3280	820
	2	115	92	23	3772	943
	3	162	129	33	5289	1353
	4	151	120	31	4920	1271
LG	1	150	120	30	4920	1230
	2	115	92	23	3772	943
NHL	CLL	113	90	23	3690	943
	FL	139	111	28	4551	1148
	MCL	122	97	25	3977	1025
UCSB	Benigno	32	25	7	1025	287
	Maligno	26	20	6	820	246

Fonte: Elaborado pelo autor.

3.4.2 Etapa 2 - Treinamento e Testes

A etapa 2 do método é destinada a separar as imagens obtidas como resultado da etapa 1 para treino e teste do modelo adaptado de *Resnet50*, levando em conta as métricas calculadas. Primeiramente, as imagens de entrada da etapa 2 são separadas para treino e teste. Durante a fase de treino, a quantidade de *epochs* varia, gerando ao fim do treinamento modelos para cada número de *epochs*, que no caso deste trabalho são 30 modelos diferentes, que depois são submetidos aos testes. A fase de teste consiste em classificar cada imagem das restantes em cada um dos modelos, calculando os diferentes valores das métricas para cada número de *epochs*.

O modelo escolhido para classificar as imagens histológicas foi a *ResNet50* adaptada e pré-treinada na base ImageNet (RUSSAKOVSKY et al., 2015), que dispõe de mil classes para classificação. As bases de imagens histológicas utilizadas nos testes e descritas na subseção 2.1.11 possuem entre duas e quatro classes para classificação, dependendo da base. Sendo assim, para o contexto do problema do trabalho, a última camada da rede, camada totalmente conectada, foi adaptada à quantidade de classes que a base de imagens possui.

Após a adaptação da rede neural para o contexto desejado, é realizado o treinamento da rede com os primeiros 80% de imagens obtidas na etapa 1. Na fase de treinamento, o número de *epochs* varia de um a 30, gerando 30 modelos diferentes, um para cada número de vezes que a base de imagens de treinamento é percorrida. Cada vez que a base de imagens é percorrida, os pesos da última camada da rede neural são atualizados a partir de algoritmo de *backpropagation* utilizando técnica de *gradient descent* (ROJAS, 1996), persistindo o conhecimento que a rede obteve durante o treinamento.

Os pesos das camadas convolucionais não são alterados por ser aplicado no trabalho estratégia de *transfer learning*, que possibilita atualizar apenas os pesos das camadas totalmente conectadas, propiciando o uso de modelos profundos mesmo utilizando

bases com poucas imagens (MAZO et al., 2018). Com o treinamento finalizado para os diferentes números de *epochs*, a fase de teste utiliza os 20% restantes de imagens obtidas na etapa 1 para classificação.

3.4.3 Etapa 3 - Cálculo das Métricas

A etapa 3 consiste em analisar os resultados obtidos na etapa de classificação para verificar se o uso combinado de coeficientes *curvelet* com CNN pode contribuir com o processo de classificação e reconhecimento de padrões nos contextos de imagens histológicas aqui exploradas. Para tanto, foram observados os valores de *loss* para cada número de *epochs*, com objetivo de encontrar o menor valor de *loss* e calcular as demais métricas, tais como acurácia, precisão, sensibilidade e F1-score. Esse procedimento foi aplicado para cada um dos *datasets* e associações de imagens.

3.5 Conjuntos de imagens

Neste trabalho, quatro composições de imagens histológicas e sub-imagens *curvelet* foram exploradas para identificar as mais relevantes, respeitando a distribuição de 80% de amostras para treino e 20% para teste. O primeiro conjunto de imagens foi constituído pelas imagens histológicas H&E originais, que será referenciado no trabalho e nos resultados como HIST. O segundo conjunto de imagens é composto por sub-imagens *curvelet* obtidas das imagens originais, utilizando as sub-imagens tanto na etapa de treino quanto na etapa de testes. Esse conjunto, referenciado no trabalho como CURV, não envolve classificação de nenhuma imagem original em nenhuma fase. O terceiro conjunto, referenciado por HC34, é composto por uma junção das imagens histológicas originais com as sub-imagens *curvelet* de escalas três e quatro. Essa combinação foi explorada para treinar e testar o modelo. O quarto conjunto utilizado no trabalho, chamado de C34H, é composto por uma junção das imagens histológicas

originais com as sub-imagens *curvelet* de escala três e quatro na fase de treinamento e apenas imagens histológicas na fase de teste do modelo. Nesse conjunto, 80% das imagens originais são submetidas à aplicação da transformada *curvelet* e as sub-imagens de escala três e quatro que representam os coeficientes obtidos são utilizadas na fase de treinamento do modelo. Assim, o conjunto remanescente de imagens histológicas (20%) foi usado diretamente como entrada para a fase de teste. Um resumo das associações exploradas neste estudo está presente na Tabela 3.3.

Tabela 3.3: Quantidade de imagens H&E e *curvelets* por tipo de associação.

Base	Fase	HIST		CURV		HC34		C34H	
		H&E	Curvelets	H&E	Curvelets	H&E	Curvelets	H&E	Curvelets
CR	Treino	131	-	-	5371	131	4192	131	4192
	Teste	34	-	-	1394	34	1088	34	-
LA	Treino	421	-	-	17261	421	13472	421	13472
	Teste	107	-	-	4387	107	3424	107	-
LG	Treino	212	-	-	8692	212	6784	212	6784
	Teste	53	-	-	2173	53	1696	53	-
NHL	Treino	298	-	-	12218	298	9536	298	9536
	Teste	76	-	-	3116	76	2432	76	-
UCSB	Treino	45	-	-	1845	45	1440	45	1440
	Teste	13	-	-	533	13	416	13	-

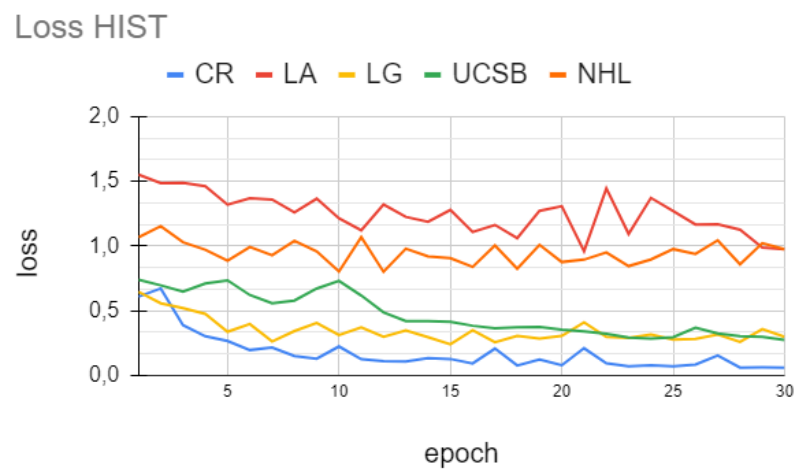
Capítulo 4

Resultados e Discussão

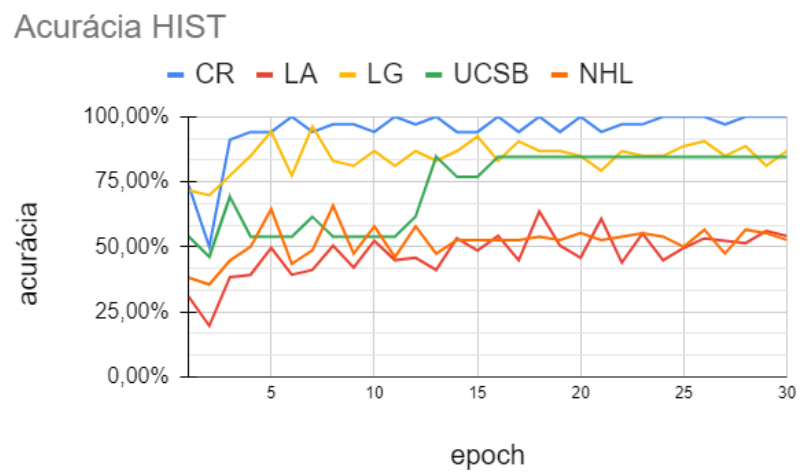
Neste capítulo são apresentados os resultados obtidos nos testes realizados para todos os conjuntos de imagens, além de uma discussão das classificações envolvendo as combinações com os coeficientes *curvelet*.

4.1 Resultados

Neste trabalho, os experimentos foram realizados a partir de diferentes combinações entre as imagens histológicas e coeficientes *curvelet*, conforme resumo apresentado na Tabela 3.3. O primeiro teste visou observar os comportamentos das métricas *loss* e acurácia do modelo CNN quando aplicado diretamente sobre as imagens histológicas (HIST). Este tipo de teste permite verificar a capacidade discriminativa da ResNet50 aplicada com o uso de transferência de aprendizado, bem como conhecer as melhores combinações, em função de variações no número de *epochs*. Os resultados estão ilustrados na Figura 4.1.

Figura 4.1: Comportamento da *loss* (a) e acurácia (b) no conjunto HIST.

(a)



(b)

Fonte: Elaborado pelo autor.

Observando os resultados ilustrados previamente, é possível verificar que as melhores taxas para as bases NHL e UCSB foram observadas com 12 e 30 *epochs*, respectivamente, sendo esses o menor e maior valores de *epochs* observados que produziram melhores resultados para suas respectivas bases. Nesses casos, os valores de *loss* (erros de previsão) foram 0,8008 e 0,2747, respectivamente. Para as demais bases, as melhores condições foram observadas com *epoch* igual a 28 nos casos de CR e LG e *epoch* igual 21 para LA, com valores de *loss* 0,0609, 0,2590 e 0,9603, respectivamente.

Nesses contextos, os menores valores de *loss* foram observados nas bases CR e LG, indicando que o modelo ResNet50 com transferência de aprendizado pode ser aplicado em conjuntos de imagens com um número reduzido de amostras. Por exemplo, este tipo de estratégia forneceu acurácias acima de 84% em três das cinco bases de imagens investigadas. A partir disso, um resumo das melhores combinações para HIST está na Tabela 4.1 com as indicações das métricas acurácia, precisão, sensibilidade e F-score. Nota-se que a melhor situação ocorreu na base CR, atingindo as taxas máximas e com o menor valor de *loss*. O pior desempenho foi na base NHL, em que há três classes envolvidas, com 51,39% de F-score e o segundo maior valor de *loss* (0,8008).

Tabela 4.1: Resultados observados das métricas para cada *dataset*.

Base	Epoch	Loss	Acurácia	Precisão	Sensibilidade	F1-score
CR	28	0,0609	100%	100%	100%	100%
LA	21	0,9603	60,75%	64,61%	62,54%	58,30%
LG	28	0,2590	88,68%	79,31%	100%	88,46%
UCSB	30	0,2747	84,62%	100%	66,67%	80%
NHL	12	0,8008	57,89%	53,17%	56,29%	51,39%

Fonte: Elaborado pelo autor.

O uso combinado de coeficientes *curvelet* também foi explorado para conhecer possíveis contribuições em relação aos resultados destacados previamente. As com-

combinações testadas foram CURV, HC34 e C34H, levando em consideração os comportamentos da *loss* em função do número de *epochs*. Na Tabela 4.2 são expostos os resultados das métricas para cada conjunto, em que as melhores combinações estão em negrito.

Tabela 4.2: Melhores combinações de métricas para cada *dataset* e conjuntos

Base	Conjunto	Epoch	Loss	Acurácia	Precisão	Sensibilidade	F1-score
CR	HIST	30	0,0612	100%	100%	100%	100%
	CURV	29	0,7188	54,09%	56,28%	79,97%	66,07%
	HC34	24	0,7960	50,53%	56,06%	53,11%	54,55%
	C34H	25	0,2175	97,06%	100%	94,74%	97,30%
LA	HIST	21	0,9603	60,75%	64,61%	62,54%	58,30%
	CURV	12	1,4140	28,13%	27,21%	25,65%	23,25%
	HC34	15	1,4173	28,49%	32,10%	25,07%	22,77%
	C34H	29	0,8104	67,29%	81,03%	64,73%	60,64%
LG	HIST	28	0,2590	88,68%	79,31%	100%	88,46%
	CURV	30	0,7276	49,84%	44,17%	59,07%	50,54%
	HC34	28	0,7295	50,09%	42,95%	45,72%	44,29%
	C34H	29	0,4879	94,34%	88,46%	100%	93,88%
UCSB	HIST	30	0,2747	84,62%	100%	66,67%	80%
	CURV	24	0,5980	68,29%	65,71%	65,45%	65,58%
	HC34	28	0,6021	70,16%	68,82%	64,65%	66,67%
	C34H	28	0,5345	69,23%	75%	50%	60%
NHL	HIST	12	0,8008	57,89%	53,17%	56,29%	51,39%
	CURV	22	1,0585	44,29%	43,77%	42,51%	40,38%
	HC34	21	1,1995	50,88%	43,93%	50,41%	41,16%
	C34H	26	1,0036	57,89%	58,95%	56,29%	52,03%

Fonte: Elaborado pelo autor.

4.2 Discussão

A partir dos resultados indicados na Tabela 4.2, observa-se que a combinação de sub-imagens *curvelet* com histológicas (C34H) forneceu os melhores resultados em três das cinco bases testadas quando as métricas precisão e F-score são consideradas. As bases de imagens foram LA, LG e NHL. É importante reforçar que a métrica F-score indica a qualidade geral do modelo inclusive quando os conjuntos analisados apresentam classes não balanceadas, como os testes envolvendo as imagens aqui exploradas. Por outro lado, o uso de HIST permitiu as melhores situações em duas bases, CR e UCSB, com acurácias de 100% e 84,62%, respectivamente.

Outros detalhes também merecem destaque. Quando o conjunto LA é considerado, de imagens de tecido do fígado em quatro estágios da vida de um rato, o conjunto C34H apresentou melhores resultados que o conjunto padrão HIST, em todas as métricas, com um aumento de 10,70% no valor da acurácia e 25,40% no valor da precisão. Um aumento na métrica de precisão pode ser interpretado como uma diminuição da média de casos classificados incorretamente, por se tratar de uma classificação multi-classe. No caso da base LG, que contém imagens de fígado de ratos de gênero masculino e feminino, foi observado um aumento de 6,30% na acurácia e aumentos parecidos na precisão e F-score, além de 100% de sensibilidade, indicando que todas as imagens de tecido de fígado de gênero masculino foram classificadas corretamente. Nesse caso, o aumento da precisão possibilita a interpretação de que houve uma diminuição no número de imagens de tecido de fígado de ratos do gênero feminino sendo classificadas como de gênero masculino.

No conjunto NHL, que contém imagens de três tipos de linfomas Não-Hodgkin, a combinação C34H indicou F-score sutilmente maior, 1,20%, e uma precisão mais significativa, de 10%, em comparação com as observadas somente com o conjunto HIST. Diante disso, foi possível verificar que o uso de imagens *curvelet*, combinação C34H, pode contribuir com o processo de classificação, mesmo que em alguns contextos o

ganho não seja expressivo. Por fim, quando o total de *epochs* é considerado, não foi possível identificar um padrão entre as combinações, mas observa-se que a associação C34H foi mais estável do que as demais, indicando resultados relevantes entre 25 e 29 *epochs*.

Com esses resultados, é possível observar que o uso da ResNet50, transferência de aprendizado e uma associação do tipo C34H pode contribuir com o processo de classificação de imagens histológicas. No entanto, apenas a adição das sub-imagens *curvelet* não foi suficiente para produzir resultados relevantes nos cinco diferentes tipos *datasets*.

Capítulo 5

Conclusões

Neste trabalho, foi proposta uma exploração da aplicação de coeficientes *curvelet* no processo de classificação de imagens histológicas. Aplicando os coeficientes em diferentes conjuntos de imagens e diferentes *datasets*, foi observado que coeficientes de escalas mais altas, nesse caso três e quatro, quando combinados com as imagens originais, produzem resultados promissores. Por outro lado, os conjuntos de imagens envolvendo somente sub-imagens *curvelet* não foram capazes de produzir resultados importantes. Essas informações são importantes e podem contribuir com o processo de projeto e desenvolvimento de métodos direcionados para a classificação de imagens com redes do tipo CNN e transformadas *curvelet*.

Por fim, quando observamos os resultados obtidos no conjunto HIST, é possível afirmar que o processo de transferência de aprendizado viabilizou o processo de classificação em *datasets* com um número reduzido de amostras. Por exemplo, a aplicação de uma CNN (ResNet50) com transferência de aprendizado na base CR, com apenas 165 amostras, permitiu atingir resultados expressivos, com 100% de F-score. Mais ainda, o uso dessa estratégia também garantiu a exploração de combinações com a transformada *curvelet* em diferentes *datasets*.

Para trabalhos futuros, é interessante investigar: 1. mais escalas de coeficientes *curvelet*, proporcionando representações com maior nível de detalhes; 2. a influência

no processo de classificação com um número maior de *epochs*; 3. o poder discriminativo obtido a partir de técnicas de aumento de dados artificiais em comparação com os resultados conquistados com a transformada *curvelet*. Por fim, é importante comparar os melhores resultados com os disponibilizados na literatura dedicada para este tipo de aplicação (imagens histológicas, CNN e transformada *curvelet*).

Referências Bibliográficas

ABRAHAM, A. Artificial neural networks. *Handbook of measuring system design*, John Wiley & Sons, Ltd Chichester, UK, 2005.

ALINSAIF, S.; LANG, J. Histological image classification using deep features and transfer learning. In: IEEE. *2020 17th Conference on Computer and Robot Vision (CRV)*. [S.l.], 2020. p. 101–108.

ARAÚJO, T.; ARESTA, G.; CASTRO, E.; ROUCO, J.; AGUIAR, P.; ELOY, C.; POLÓNIA, A.; CAMPILHO, A. Classification of breast cancer histology images using convolutional neural networks. *PloS one*, Public Library of Science San Francisco, CA USA, v. 12, n. 6, p. e0177544, 2017.

BARATLOO, A.; HOSSEINI, M.; NEGIDA, A.; ASHAL, G. E. Part 1: simple definition and calculation of accuracy, sensitivity and specificity. *ARCHIVES OF ACADEMIC EMERGENCY MEDICINE (EMERGENCY)*, 2015.

BRUNO, D. O. T.; NASCIMENTO, M. Z. D.; RAMOS, R. P.; BATISTA, V. R.; NEVES, L. A.; MARTINS, A. S. Lbp operators on curvelet coefficients as an algorithm to describe texture in breast cancer tissues. *Expert Systems with Applications*, Elsevier, v. 55, p. 329–340, 2016.

CANDES, E.; DEMANET, L.; DONOHO, D.; YING, L. Fast discrete curvelet transforms. *Multiscale Modeling & Simulation*, SIAM, v. 5, n. 3, p. 861–899, 2006.

CANDES, E. J.; DONOHO, D. L. *Curvelets: A surprisingly effective nonadaptive representation for objects with edges*. [S.l.], 2000.

DENG, S.; ZHANG, X.; YAN, W.; ERIC, I.; CHANG, C.; FAN, Y.; LAI, M.; XU, Y. Deep learning in digital pathology image analysis: A survey. *Frontiers of medicine*, Springer, p. 1–18, 2020.

EID, A.; CHARISIS, V. S.; HADJILEONTIADIS, L. J.; SERGIADIS, G. D. A curvelet-based lacunarity approach for ulcer detection from wireless capsule endoscopy images. In: IEEE. *Proceedings of the 26th IEEE International Symposium on Computer-Based Medical Systems*. [S.l.], 2013. p. 273–278.

ELTOUKHY, M. M.; FAYE, I.; SAMIR, B. B. Breast cancer diagnosis in digital mammogram using multiscale curvelet transform. *Computerized medical imaging and graphics*, Elsevier, v. 34, n. 4, p. 269–276, 2010.

- ELTOUKHY, M. M.; FAYE, I.; SAMIR, B. B. A comparison of wavelet and curvelet for breast cancer diagnosis in digital mammogram. *Computers in Biology and Medicine*, Elsevier, v. 40, n. 4, p. 384–391, 2010.
- ELTOUKHY, M. M.; FAYE, I.; SAMIR, B. B. Curvelet based feature extraction method for breast cancer diagnosis in digital mammogram. In: IEEE. *2010 International Conference on Intelligent and Advanced Systems*. [S.l.], 2010. p. 1–5.
- ELTOUKHY, M. M.; GARDEZI, S. J. S.; FAYE, I. A method to reduce curvelet coefficients for mammogram classification. In: IEEE. *2014 IEEE Region 10 Symposium*. [S.l.], 2014. p. 663–666.
- FISCHER, A. H.; JACOBSON, K. A.; ROSE, J.; ZELLER, R. Hematoxylin and eosin staining of tissue and cell sections. *Cold spring harbor protocols*, Cold spring harbor laboratory press, v. 2008, n. 5, p. pdb–prot4986, 2008.
- FU, X.; LIU, T.; XIONG, Z.; SMAILL, B. H.; STILES, M. K.; ZHAO, J. Segmentation of histological images and fibrosis identification with a convolutional neural network. *Computers in biology and medicine*, Elsevier, v. 98, p. 147–158, 2018.
- GARTNER, L. P.; HIATT, J. L. *Color textbook of histology e-book*. [S.l.]: Elsevier Health Sciences, 2006.
- GELASCA, E. D.; BYUN, J.; OBARA, B.; MANJUNATH, B. Evaluation and benchmark for biological image segmentation. In: IEEE. *2008 15th IEEE International Conference on Image Processing*. [S.l.], 2008. p. 1816–1819.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. <<http://www.deeplearningbook.org>>.
- GÖRGEL, P. A brain tumor detection system using gradient based watershed marked active contours and curvelet transform. *Transactions on Emerging Telecommunications Technologies*, Wiley Online Library, v. 32, n. 9, p. e4170, 2021.
- GU, J.; WANG, Z.; KUEN, J.; MA, L.; SHAHROUDY, A.; SHUAI, B.; LIU, T.; WANG, X.; WANG, G.; CAI, J. et al. Recent advances in convolutional neural networks. *Pattern Recognition*, Elsevier, v. 77, p. 354–377, 2018.
- GUO, S.; YANG, Z. Multi-channel-resnet: An integration framework towards skin lesion analysis. *Informatics in Medicine Unlocked*, Elsevier, v. 12, p. 67–74, 2018.
- GUYON, I.; GUNN, S.; NIKRAVESH, M.; ZADEH, L. A. *Feature extraction: foundations and applications*. [S.l.]: Springer, 2008. v. 207.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 770–778.

- HEARST, M. A.; DUMAIS, S. T.; OSUNA, E.; PLATT, J.; SCHOLKOPF, B. Support vector machines. *IEEE Intelligent Systems and their applications*, IEEE, v. 13, n. 4, p. 18–28, 1998.
- HOPFIELD, J. J. Artificial neural networks. *IEEE Circuits and Devices Magazine*, IEEE, v. 4, n. 5, p. 3–10, 1988.
- IANDOLA, F. N.; HAN, S.; MOSKEWICZ, M. W.; ASHRAF, K.; DALLY, W. J.; KEUTZER, K. Squeezenet: Alexnet-level accuracy with 50x fewer parameters and < 0.5 mb model size. *arXiv preprint arXiv:1602.07360*, 2016.
- JANOCHA, K.; CZARNECKI, W. M. On loss functions for deep neural networks in classification. *arXiv preprint arXiv:1702.05659*, 2017.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *nature*, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015.
- LEUNG, H. Y.; CHENG, L.-M.; CHENG, L. L. A robust watermarking scheme using selective curvelet coefficients. *International Journal of Wavelets, Multiresolution and Information Processing*, World Scientific, v. 7, n. 02, p. 163–181, 2009.
- LI, Y.; YANG, Q.; JIAO, R. Image compression scheme based on curvelet transform and support vector machine. *Expert Systems with Applications*, Elsevier, v. 37, n. 4, p. 3063–3069, 2010.
- LIN, W.-C.; LI, C.-C.; CHRISTUDASS, C. S.; EPSTEIN, J. I.; VELTRI, R. W. Curvelet-based classification of prostate cancer histological images of critical gleason scores. In: IEEE. *2015 IEEE 12th International Symposium on Biomedical Imaging (ISBI)*. [S.l.], 2015. p. 1020–1023.
- LIPTON, Z. C.; ELKAN, C.; NARYANASWAMY, B. Optimal thresholding of classifiers to maximize f1 measure. In: SPRINGER. *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*. [S.l.], 2014. p. 225–239.
- LIU, G.; YAN, G.; KUANG, S.; WANG, Y. Detection of small bowel tumor based on multi-scale curvelet analysis and fractal technology in capsule endoscopy. *Computers in biology and medicine*, Elsevier, v. 70, p. 131–138, 2016.
- MAHMOOD, A.; OSPINA, A. G.; BENNAMOUN, M.; AN, S.; SOHEL, F.; BOUSSAID, F.; HOVEY, R.; FISHER, R. B.; KENDRICK, G. A. Automatic hierarchical classification of kelps using deep residual features. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 20, n. 2, p. 447, 2020.
- MAZO, C.; BERNAL, J.; TRUJILLO, M.; ALEGRE, E. Transfer learning for classification of cardiovascular tissues in histological images. *Computer methods and programs in biomedicine*, Elsevier, v. 165, p. 69–76, 2018.
- MIRANDA, E.; ARYUNI, M.; IRWANSYAH, E. A survey of medical image classification techniques. In: IEEE. *2016 International Conference on Information Management and Technology (ICIMTech)*. [S.l.], 2016. p. 56–61.

MYLES, A. J.; FEUDALE, R. N.; LIU, Y.; WOODY, N. A.; BROWN, S. D. An introduction to decision tree modeling. *Journal of Chemometrics: A Journal of the Chemometrics Society*, Wiley Online Library, v. 18, n. 6, p. 275–285, 2004.

NAYAK, D. R.; DASH, R.; MAJHI, B.; PRASAD, V. Automated pathological brain detection system: A fast discrete curvelet transform and probabilistic neural network based approach. *Expert Systems with Applications*, Elsevier, v. 88, p. 152–164, 2017.

PANTANOWITZ, L.; VALENSTEIN, P. N.; EVANS, A. J.; KAPLAN, K. J.; PFEIFFER, J. D.; WILBUR, D. C.; COLLINS, L. C.; COLGAN, T. J. Review of the current state of whole slide imaging in pathology. *Journal of pathology informatics*, Wolters Kluwer–Medknow Publications, v. 2, 2011.

RAHMAN, T.; KHANDAKAR, A.; KADIR, M. A.; ISLAM, K. R.; ISLAM, K. F.; MAZHAR, R.; HAMID, T.; ISLAM, M. T.; KASHEM, S.; MAHBUB, Z. B. et al. Reliable tuberculosis detection using chest x-ray with deep learning, segmentation and visualization. *IEEE Access*, IEEE, v. 8, p. 191586–191601, 2020.

RIBANI, R.; MARENGONI, M. A survey of transfer learning for convolutional neural networks. In: IEEE. *2019 32nd SIBGRAPI Conference on Graphics, Patterns and Images Tutorials (SIBGRAPI-T)*. [S.l.], 2019. p. 47–57.

RIBEIRO, M. G.; NEVES, L. A.; NASCIMENTO, M. Z. do; ROBERTO, G. F.; MARTINS, A. S.; TOSTA, T. A. A. Classification of colorectal cancer based on the association of multidimensional and multiresolution features. *Expert Systems with Applications*, Elsevier, v. 120, p. 262–278, 2019.

ROBERT, H.-N. et al. Theory of the backpropagation neural network. *Proc. 1989 IEEE IJCNN*, v. 1, p. 593–605, 1989.

ROFFO, G.; MELZI, S.; CASTELLANI, U.; VINCIARELLI, A. Infinite latent feature selection: A probabilistic latent graph-based ranking approach. In: *Proceedings of the IEEE International Conference on Computer Vision*. [S.l.: s.n.], 2017. p. 1398–1406.

ROJAS, R. The backpropagation algorithm. In: *Neural networks*. [S.l.]: Springer, 1996. p. 149–182.

RUSSAKOVSKY, O.; DENG, J.; SU, H.; KRAUSE, J.; SATHEESH, S.; MA, S.; HUANG, Z.; KARPATY, A.; KHOSLA, A.; BERNSTEIN, M. et al. Imagenet large scale visual recognition challenge. *International journal of computer vision*, Springer, v. 115, n. 3, p. 211–252, 2015.

SARASWATHI, D.; DHARANI, D.; SRINIVASAN, E. An efficient feature extraction technique for breast cancer diagnosis using curvelet transform and swarm intelligence. In: IEEE. *2016 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET)*. [S.l.], 2016. p. 441–445.

SASAKI, Y.; FELLOW, R. The truth of the f-measure, manchester: Mib-school of computer science. *University of Manchester*, p. 25, 2007.

- SENGUPTA, A.; YE, Y.; WANG, R.; LIU, C.; ROY, K. Going deeper in spiking neural networks: Vgg and residual architectures. *Frontiers in neuroscience*, Frontiers, v. 13, p. 95, 2019.
- SHAMIR, L.; ORLOV, N.; ECKLEY, D. M.; MACURA, T. J.; GOLDBERG, I. G. Iicbu 2008: a proposed benchmark suite for biological image analysis. *Medical & biological engineering & computing*, Springer, v. 46, n. 9, p. 943–947, 2008.
- SHARMA, S.; SHARMA, S.; ATHAIYA, A. Activation functions in neural networks. *towards data science*, v. 6, n. 12, p. 310–316, 2017.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- SIRINUKUNWATTANA, K.; PLUIM, J. P.; CHEN, H.; QI, X.; HENG, P.-A.; GUO, Y. B.; WANG, L. Y.; MATUSZEWSKI, B. J.; BRUNI, E.; SANCHEZ, U. et al. Gland segmentation in colon histology images: The glas challenge contest. *Medical image analysis*, Elsevier, v. 35, p. 489–502, 2017.
- TIAN, D. ping et al. A review on image feature extraction and representation techniques. *International Journal of Multimedia and Ubiquitous Engineering*, Citeseer, v. 8, n. 4, p. 385–396, 2013.
- TORREY, L.; SHAVLIK, J. Transfer learning. In: *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques*. [S.l.]: IGI global, 2010. p. 242–264.
- UCAR, F.; KORKMAZ, D. Covidiagnosis-net: Deep bayes-squeezenet based diagnosis of the coronavirus disease 2019 (covid-19) from x-ray images. *Medical hypotheses*, Elsevier, v. 140, p. 109761, 2020.
- WANG, Z.; CUI, P.; LI, F.; CHANG, E.; YANG, S. A data-driven study of image feature extraction and fusion. *Information Sciences*, Elsevier, v. 281, p. 536–558, 2014.
- WU, J. Introduction to convolutional neural networks. *National Key Lab for Novel Software Technology. Nanjing University. China*, v. 5, n. 23, p. 495, 2017.
- WU, Z.; SHEN, C.; HENGEL, A. V. D. Wider or deeper: Revisiting the resnet model for visual recognition. *Pattern Recognition*, Elsevier, v. 90, p. 119–133, 2019.
- YASIRAN, S. S.; SALLEH, S.; SARMIN, N.; MAHMUD, R.; HALIM, S. A. Curvelet based texture features for breast cancer classifications. In: IOP PUBLISHING. *Journal of Physics: Conference Series*. [S.l.], 2021. v. 1988, n. 1, p. 012037.
- YOON, H.; LEE, J.; OH, J. E.; KIM, H. R.; LEE, S.; CHANG, H. J.; SOHN, D. K. Tumor identification in colorectal histology images using a convolutional neural network. *Journal of digital imaging*, Springer, v. 32, n. 1, p. 131–140, 2019.

ZAHN, J. M.; POOSALA, S.; OWEN, A. B.; INGRAM, D. K.; LUSTIG, A.; CARTER, A.; WEERARATNA, A. T.; TAUB, D. D.; GOROSPE, M.; MAZANMAMCZARZ, K. et al. Agemap: a gene expression database for aging in mice. *PLoS genetics*, Public Library of Science San Francisco, USA, v. 3, n. 11, p. e201, 2007.

ZHANG, Y.; ZHANG, B.; COENEN, F.; LU, W. Breast cancer diagnosis from biopsy images with highly reliable random subspace classifier ensembles. *Machine vision and applications*, Springer, v. 24, n. 7, p. 1405–1420, 2013.

ZHOU, S. K.; GREENSPAN, H.; SHEN, D. *Deep learning for medical image analysis*. [S.l.]: Academic Press, 2017.

ZHUANG, F.; QI, Z.; DUAN, K.; XI, D.; ZHU, Y.; ZHU, H.; XIONG, H.; HE, Q. A comprehensive survey on transfer learning. *Proceedings of the IEEE*, IEEE, v. 109, n. 1, p. 43–76, 2020.