

RESSALVA

Atendendo solicitação da autora, o texto completo desta dissertação será disponibilizado somente a partir de 01/02/2025.



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

Jaqueline Junko Tenguan

Ensemble Learning como Estratégia para
Investigar Imagens H&E utilizando
Duplo Estágio de Seleção de Atributos

São José do Rio Preto
2023

Jaqueline Junko Tengam

Ensemble Learning como Estratégia para
Investigar Imagens H&E utilizando
Duplo Estágio de Seleção de Atributos

Dissertação apresentada como parte dos requisitos para obtenção do título de Mestre em Ciência da Computação, junto ao Programa de Pós-Graduação PPGCC – Programa de Pós-Graduação 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.

Financiadora: CAPES

Orientador: Prof. Dr. Leandro Alves
Neves

São José do Rio Preto
2023

T292e

Tengum, Jaqueline Junko

Ensemble learning como estratégia para investigar imagens H&E utilizando duplo estágio de seleção de atributos / Jaqueline Junko Tengum. -- São José do Rio Preto, 2023

140 f. : il., tabs.

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp), Instituto de Biociências Letras e Ciências Exatas, São José do Rio Preto

Orientador: Leandro Alves Neves

1. Ensemble learning. 2. Descritores handcrafted. 3. Descritores deep learned. 4. Imagens histológicas. 5. Duplo estágio de seleção de atributos. 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.

Jaqueline Junko Tenguan

Ensemble Learning como Estratégia para
Investigar Imagens H&E utilizando
Duplo Estágio de Seleção de Atributos

Dissertação apresentada como parte dos requisitos para obtenção do título de Mestre em Ciência da Computação, junto ao Programa de Pós-Graduação PPGCC – Programa de Pós-Graduação 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.

Financiadora: CAPES

Comissão Examinadora

Prof. Dr. Leandro Alves Neves
UNESP – Câmpus de São José do Rio Preto
Orientador

Prof. Dr. Denis Henrique Pinheiro Salvadeo
UNESP – Câmpus de Rio Claro

Prof. Dr. André Ricardo Backes
UFSCar – Universidade Federal de São Carlos

São José do Rio Preto
01 de fevereiro de 2023

Ao meu querido amigo Rodolfo Rodrigues Simões (in memoriam).

Agradecimentos

Agradeço ao meu orientador Prof. Dr. Leandro Alves Neves por todo o apoio, compreensão e incentivo que demonstrou durante todo o tempo em que estivemos trabalhando juntos.

Agradeço aos meus amigos e familiares por sempre estarem ao meu lado, apoiando e incentivando a minha carreira acadêmica e, acima de tudo, por sempre se orgulharem de tudo o que conquistei até aqui.

O orientador deste projeto agradece o apoio financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), #313643/2021-0, Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), #2022/03020-1, e da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), #APQ01129-21 e #APQ-00578-18.

Finalmente, agradeço ao apoio financeiro fornecido pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), código de financiamento 001, para o desenvolvimento deste trabalho.

"Continue a nadar."

- Dory (Procurando Nemo)

Resumo

Neste trabalho, é apresentada uma investigação de *ensemble learning* para o contexto de imagens médicas, especificamente o reconhecimento de padrões em amostras histológicas tingidas com Hematoxilina e Eosina. As bases exploradas foram representativas do câncer colorretal, displasia oral epitelial, linfomas não-Hodgkin e tecidos hepáticos. A estratégia de *ensemble learning* foi considerada a partir de múltiplos descritores, tais como *deep learned* e *handcrafted*, e múltiplos classificadores. Os descritores *deep learned* foram calculados explorando cinco distintas arquiteturas de redes neurais convolucionais. Os descritores *handcrafted* foram representativos das categorias fractais multidimensionais e multiescala, Haralick e *Local Binary Pattern*. As principais combinações de descritores, conseqüentemente de técnicas, foram obtidas por meio de duplo estágio de seleção de atributos (ranqueamento com meta-heurísticas) e classificadas via um *ensemble* de classificadores compostos por múltiplos classificadores: *Support Vector Machine*, *Naive Bayes*, *Random Forest*, Regressão Logística e *K-Nearest Neighbors*. As taxas de acurácias foram valores entre 90,72% e 100,00%, com alguns destaques envolvendo combinações de técnicas capazes de aprimorar as acurácias em diferentes contextos de imagens histológicas; análise dos atributos presentes nas melhores soluções obtidas; e definição de combinações de *ensembles* com desempenhos competitivos em relação aos disponíveis na literatura, explorando um número reduzido de atributos.

Palavras-chave: *Ensemble learning*. Descritores *handcrafted*. Descritores *deep learned*. Imagens histológicas. Duplo estágio de seleção de atributos.

Abstract

In this work, an ensemble learning investigation is presented for the context of medical images, specifically the recognition of patterns in histological samples stained with Hematoxylin and Eosin. The datasets explored were representative of colorectal cancer, oral epithelial dysplasia, non-Hodgkin lymphoma, and liver tissue. The ensemble learning strategy was considered from multiple descriptors, such as deep learned and handcrafted, and multiple classifiers. The deep learned features were calculated by exploring five different architectures of convolutional neural network. The handcrafted features were representative of the multidimensional and multiscale fractal, Haralick and Local Binary Pattern categories. The main combinations of descriptors, consequently of techniques, were obtained through a two-stage feature selection (ranking with metaheuristics) and classified via an ensemble of classifiers composed of multiple classifiers: Support Vector Machine, Naive Bayes, Random Forest, Logistic Regression, and K-Nearest Neighbors. The accuracy rates were values between 90.72% and 100.00%, with some highlights involving combinations of techniques capable of improving accuracy in different histological image contexts; analysis of the features present in the best solutions obtained; and definition of ensemble combinations with competitive performances compared to those available in the literature, exploring a reduced number of descriptors.

Keywords: *Ensemble learning. Handcrafted features. Deep learned features. Histological images. Two-stage feature selection.*

Lista de Figuras

2.1	Ângulos θ considerados para o cálculo da matriz de co-ocorrência. . .	31
2.2	Exemplificação do processo de construção da matriz de co-ocorrência, com $\delta = 1$ e $\theta = 0^\circ$: (a) Imagem original, com a indicação de pares de <i>pixels</i> vizinhos; (b) Estágio de incrementação do valor na matriz após analisar os <i>pixels</i> vizinhos destacados em (a); (c) Matriz de co-ocorrência resultante da imagem (a).	32
2.3	Diferentes configurações de vizinhança (PN, R) para o método LBP. .	33
2.4	Obtenção do código LBP, considerando $R = 1$ e $PN = 8$	33
2.5	Exemplo de arquitetura CNN, considerando um problema de classificação de veículos.	36
2.6	Exemplo do processo de convolução de uma imagem 4×4 com um filtro de tamanho 2×2 e o resultado da operação.	37
2.7	Saídas de cada camada (horizontal) de uma CNN. Cada imagem é um mapa de características correspondente à saída das características aprendidas na camada anterior, detectada em cada posição da imagem.	38
2.8	Operação de <i>max pooling</i>	39
2.9	Ilustrações de funções de ativação: Sigmoides, à esquerda; ReLU, à direita.	40
2.10	Arquitetura do modelo VGG-19.	43
2.11	Ilustração de um bloco residual na arquitetura ResNet-50.	43
2.12	Arquitetura ResNet-50.	44
2.13	Arquitetura da rede Inception v3.	45

2.14	Redução do tamanho do <i>grid</i> . O diagrama na direita representa a mesma solução à esquerda, mas da perspectiva de tamanho do <i>grid</i> ao invés de operações.	46
2.15	Arquitetura DenseNet-121.	47
2.16	Arquitetura EfficientNet-B0.	48
2.17	Duas principais arquiteturas de <i>ensemble</i> . S_i , h_i e $H(x)$ indicam a i -ésima amostra de dados, o i -ésimo classificador e a regra de combinação, respectivamente.	56
2.18	Ilustração das quatro abordagens para a criação de um <i>ensemble</i>	57
2.19	Combinação baseada em regras fixas em um problema com quatro classes e um <i>ensemble</i> de três classificadores.	59
2.20	Gráfico de comparação entre três curvas ROC.	61
2.21	Exemplos de imagens histológicas H&E.	63
4.1	Ilustração do método proposto.	88
4.2	Ilustração do método <i>gliding box</i> considerando $L = 3$ (a) e $L = 5$ (b), com um hipercubo, representado em vermelho, deslocando-se na imagem até o canto inferior.	90
4.3	Esquema do <i>ensemble</i> proposto em que as caixas com linhas tracejadas definem que apenas um dos seus componentes foi utilizado para compor o <i>ensemble</i>	104
4.4	Exemplos de imagens NHL (a), OED (b), CR (c), LG (d) e LA (e).	105
5.1	Ocorrências de descritores <i>deep learned</i> presentes nas <i>top 10</i> soluções das bases CR, LG e NHL.	112
5.2	Ocorrência dos descritores <i>handcrafted</i> nas <i>top 10</i> soluções para as bases LA, OED, NHL e LG.	113

Lista de Tabelas

2.1	Matriz de confusão com as quatro classificações possíveis.	60
3.1	Sumarização dos principais trabalhos correlatos que utilizaram <i>ensemble</i> de descritores para análises de imagens médicas.	86
3.2	Visão geral dos trabalhos que utilizaram duplo estágio de seleção em diferentes contextos de análise.	87
4.1	Ilustração de uma matriz de probabilidades.	91
4.2	Resumo de cada modelo CNN investigado neste projeto.	100
4.3	Nome, medida de distância considerada e o total de características <i>handcrafted</i> resultante.	102
4.4	Número de descritores extraídos e sua referente camada em cada arquitetura.	102
4.5	Informações gerais das bases de imagens utilizadas no trabalho. . . .	106
5.1	Acurácias médias obtidas pelo método proposto, utilizando dois estágios de seleção (ReliefF + <i>Wrapper</i>). As melhores acurácias estão destacadas em negrito.	109
5.2	Principais combinações em cada conjunto H&E a partir do critério maior acurácia com o menor número de descritores.	110
5.3	Acurácias fornecidas pelas arquiteturas CNN após processo de <i>fine-tuning</i> : os melhores resultados estão em negrito.	114
5.4	Teste de Friedman: ranqueamento dos métodos.	116

5.5	Visão geral dos valores de acurácias obtidos por diferentes abordagens para a classificação de imagens de câncer colorretal (CR).	117
5.6	Visão geral dos valores de acurácias obtidos por diferentes abordagens para a classificação de imagens de displasia oral (OED).	118
5.7	Visão geral dos valores de acurácias obtidos por diferentes abordagens para a classificação de imagens de fígado (LA e LG).	118
5.8	Visão geral dos valores de acurácias obtidos por diferentes abordagens para a classificação de imagens de linfomas (NHL).	118
A.1	Acurácias e outras informações complementares obtidas nos 10 testes executados para cada combinação <i>ensemble</i> de descritores + seletor <i>wrapper</i> no <i>dataset</i> CR.	138
A.2	Acurácias e outras informações complementares obtidas nos 10 testes executados para cada combinação <i>ensemble</i> de descritores + seletor <i>wrapper</i> no <i>dataset</i> OED.	139
A.3	Acurácias e outras informações complementares obtidas nos 10 testes executados para cada combinação <i>ensemble</i> de descritores + seletor <i>wrapper</i> no <i>dataset</i> LA.	139
A.4	Acurácias e outras informações complementares obtidas nos 10 testes executados para cada combinação <i>ensemble</i> de descritores + seletor <i>wrapper</i> no <i>dataset</i> LG.	140
A.5	Acurácias e outras informações complementares obtidas nos 10 testes executados para cada combinação <i>ensemble</i> de descritores + seletor <i>wrapper</i> no <i>dataset</i> NHL.	140

Lista de Abreviações

ACC Acurácia

AHP *Adaptive Hybrid Pattern*

AUC *Area Under the ROC Curve*

bGWO binary Grey Wolf Optimization

CLBP *Completed LBP*

CLM *CodebookLess Model*

CNN *Convolutional Neural Network*

COL *Color descriptor*

CR Colorretal

DL *Deep Learned*

FBSIF *Full Binarized Statistical Image Feature*

GA Algoritmo Genético

GLCM *Gray-level Co-occurrence Matrix*

GOLD *Gaussian Of Local Descriptors*

H&E Hematxilina-Eosina

HF *Handcrafted*

HOG *Histogram of Oriented Gradients*

HSL *Hue Saturation Luminosity*

ILSVRC *ImageNet Large Scale Visual Recognition Challenge*

ISIC *International Skin Imaging Collaboration*

KNN *K-Nearest Neighbors*

LA *Liver Aging*

LBP *Local Binary Patterns*

LET *LETRIST (Locally Encoded Transform Feature Histogram) Descriptor*

LG *Liver Gender*

LightGBM *Light Gradient-Boosting Machine*

LTP *Local Ternary Patterns*

MLPQ *Multithreshold LPQ*

MOR *Morphological Descriptor*

MRI *Magnetic Resonance Imaging*

NHL *Linfoma Não-Hodgkin*

OED *Displasia Epitelial Oral*

PSO *Particle Swarm Optimization*

RBF *Radial Basis Function*

RGB *Red Green Blue*

RIC *Rotation Invariant Co-occurrence*

ROC *Receiver Operating Characteristic*

ROI *Region of Interest*

SIFT *Scale-invariant Feature Transform*

SVM *Support Vector Machine*

Sumário

1	INTRODUÇÃO	19
1.1	Motivação e Justificativas	23
1.2	Objetivos	24
1.3	Considerações Finais sobre a Introdução	25
2	FUNDAMENTAÇÃO TEÓRICA	27
2.1	Extração de Características	27
2.2	Técnicas Fractais	28
2.2.1	Dimensão Fractal	29
2.2.2	Lacunaridade	29
2.2.3	Percolação	30
2.3	Descritores de Haralick	30
2.4	<i>Local Binary Patterns</i> – LBP	32
2.5	<i>Deep Learning</i>	34
2.6	Redes Neurais Convolucionais	35
2.6.1	Camada Convolucional	36
2.6.2	<i>Pooling</i>	38
2.6.3	Função de Ativação	39
2.6.4	Transferência de Aprendizado	40
2.7	Arquiteturas de Redes Neurais Convolucionais	41
2.7.1	VGG-19	42
2.7.2	ResNet-50	42

2.7.3	Inception v3	44
2.7.4	DenseNet-121	46
2.7.5	EfficientNet	47
2.8	Técnicas para Seleção de Características	49
2.9	Classificadores	52
2.10	<i>Ensemble Learning</i>	55
2.11	Métricas para Avaliação de Desempenho	58
2.12	Imagens Histológicas	62
2.13	Considerações Finais sobre a Fundamentação Teórica	62
3	TRABALHOS RELACIONADOS	65
3.1	Técnicas Fractais Multidimensionais e Multiescala	65
3.2	Descritores de Haralick	68
3.3	Descritores LBP	70
3.4	Redes Neurais Convolucionais	71
3.5	<i>Ensemble de Descritores Deep Learned e Handcrafted sem o uso Ensemble de Classificadores</i>	75
3.6	<i>Ensemble de Descritores Deep Learned e Handcrafted com o uso de Ensemble de Classificadores</i>	78
3.7	Duplo estágio de Seleção de Atributos	82
3.8	Considerações sobre os Trabalhos Relacionados	84
4	MATERIAIS E MÉTODOS	88
4.1	Descritores <i>handcrafted</i> – Técnicas fractais multidimensionais e multiescala	89
4.1.1	Dimensão fractal baseada em abordagem probabilística	89
4.1.2	Dimensão fractal baseada em abordagem de fusão de caixas	91
4.1.3	Dimensão fractal de Higuchi multidimensional e multiescala	92

4.1.4	Lacunaridade	94
4.1.5	Percolação multidimensional e multiescala	95
4.1.6	Métricas obtidas das Curvas dos descritores	96
4.2	Descritores <i>handcrafted</i> – Haralick	98
4.3	Descritores <i>handcrafted</i> – <i>Local Binary Pattern</i> (LBP)	99
4.4	Descritores <i>deep learned</i>	99
4.5	<i>Ensemble</i> de descritores	100
4.6	Análises de descritores via duplo estágio de seleção e <i>ensemble</i> de classificadores	101
4.6.1	<i>Ensemble Learning</i>	103
4.7	Contextos de aplicação	104
4.8	Pacotes de <i>software</i> e ambiente para os experimentos	106
4.9	Considerações Finais sobre Materiais e Métodos	107
5	RESULTADOS E DISCUSSÃO	108
5.1	Ocorrências dos descritores nas principais soluções: uma visão geral	111
5.2	Visão Geral frente a diferentes abordagens	114
5.2.1	Observações em relação aos trabalhos correlatos	116
6	CONCLUSÃO	119
6.1	Trabalhos Futuros	121
6.2	Contribuições	121
	REFERÊNCIAS	122
A	RESULTADOS OBTIDOS	138

Capítulo 1

Introdução

Técnicas computacionais para a análise de imagens têm contribuído significativamente para o desenvolvimento e aprimoramento de sistemas de apoio ao diagnóstico de doenças, os denominados *Computer-Aided Detection (CAD)* (ARAÚJO et al., 2017; CHAN; HADJIISKI; SAMALA, 2020; TANG et al., 2009). Para tanto, diversas combinações de métodos são explorados nestes sistemas, sendo alguns deles direcionados para apoiar a detecção de uma doença via análise histopatológica (ARAÚJO et al., 2017; IFTIKHAR; HASSAN; ALQUHAYZ, 2016; JØRGENSEN et al., 2017; KLONOWSKI et al., 2013; RIBEIRO et al., 2019). Este tipo de análise consiste em utilizar microscopia de luz para investigar amostras de tecidos (JUNQUEIRA; CARNEIRO, 2013; NAYAK; MISHRA, 2016). As várias etapas necessárias no processo de preparação das amostras podem interferir na organização das estruturas, fato que proporciona ainda mais dificuldades para um diagnóstico preciso dos diferentes níveis de uma doença sob análise. Somado a tal problemática, este tipo de análise demanda tempo e pode ser suscetível a erros de interpretação, decorrentes de uma variedade de situações envolvendo o histopatologista (AKBAR; GOPI; BABU, 2015; ALTUNBAY et al., 2010; IFTIKHAR; HASSAN; ALQUHAYZ, 2016).

Neste contexto, dois principais grupos de descritores são comumente explorados para o desenvolvimento dos sistemas CAD. O primeiro deles é o de descritores *hand-*

crafted (HF), os quais são definidos por métodos de extração distintos, geralmente visando superar problemas específicos (HASSAN et al., 2022; NANNI; GHIDONI; BRAHNAM, 2017; NANNI et al., 2020; SETHY; BEHERA, 2022). Dentre os atributos *handcrafted*, é possível destacar as abordagens baseadas em técnicas fractais multiescalas e/ou multidimensionais (BAISH; JAIN, 2000; IVANOVICI; RICHARD, 2011; LI et al., 2012; LOPES; BETROUNI, 2009; ROBERTO et al., 2021), Haralick (HARALICK; SHANMUGAM; DINSTEN, 1973) e *Local Binary Pattern* (LBP) (OJALA; PIETIKÄINEN; HARWOOD, 1996). Por exemplo, Haralick e LBP têm sido explorados em diversos contextos de imagens (ALMARAZ-DAMIAN et al., 2020; NKETIAH et al., 2017; WIBMER et al., 2015), com destaque para subsidiar as identificações de subtipos de câncer de pulmão (WANG; YU, 2013), malignidade de amostras de tecido mamário (FONDÓN et al., 2018; HASSAN et al., 2022) e classificação de câncer colorretal (AKBAR; GOPI; BABU, 2015). De maneira complementar, as técnicas fractais multiescalas e/ou multidimensionais também indicaram resultados relevantes para quantificar arquiteturas patológicas de tumores (BAISH; JAIN, 2000; LI et al., 2012; LOPES; BETROUNI, 2009), com destaque para o câncer de próstata (NEVES et al., 2014), linfomas (ROBERTO et al., 2017), neoplasia intraepitelial anal (KLONOWSKI et al., 2018), tumores de mama (ROBERTO et al., 2019), câncer colorretal (RIBEIRO et al., 2019) e lesões psoriáticas (IVANOVICI; RICHARD; DECEAN, 2009).

O segundo grupo é constituído por atributos aprendidos (*learned features*) via redes neurais convolucionais (CNN) (BUDNIK et al., 2017), especialmente. Assim, por exemplo, os modelos de redes são aplicados em amostras de imagens de uma coleção e os parâmetros obtidos durante a fase de treinamento possibilitam a extração de vetores de características (BUDNIK et al., 2017). Este tipo de estratégia tem embasado inúmeras técnicas para analisar imagens médicas (ELMANNAI; HAMDI; ALGARNI, 2021; GREENSPAN; GINNEKEN; SUMMERS, 2016; JASTI et al., 2022;

KASSANI et al., 2019; LITJENS et al., 2017). Isso é possível porque o aprendizado profundo permite que redes CNN, compostas por várias camadas de processamento simples e não-lineares, aprendam representações de dados com vários níveis de abstração. Com isso, as entradas brutas são transformadas em representações abstratas de nível mais alto (LECUN; BENGIO; HINTON, 2015), com aplicações nas mais diferentes tarefas (AL-MASNI et al., 2017; ARAÚJO et al., 2017; KASSANI et al., 2019). É importante destacar que os modelos mais explorados são aqueles que se destacaram com as melhores taxas de acurácias na competição de classificação do banco de imagens ImageNet (RUSSAKOVSKY et al., 2015), tais como: AlexNet (KRIZHEVSKY; SUTSKEVER; HINTON, 2012), GoogleNet (SZEGEDY et al., 2015a), VGGNet (SIMONYAN; ZISSERMAN, 2014), ResNet (HE et al., 2016), Inception (SZEGEDY et al., 2015a) e outras variantes (ALMARAZ-DAMIAN et al., 2020; NANNI et al., 2020; RAJINIKANTH et al., 2020).

Apesar dos avanços conquistados explorando os grupos de características apontados previamente, pesquisas foram desenvolvidas com o intuito de explorar o desempenho de modelos que combinaram ambos os tipos de atributos, *handcrafted* e *deep learned* (DL) (ALMARAZ-DAMIAN et al., 2020; HASSAN et al., 2022; NANNI; GHIDONI; BRAHNAM, 2018; RAJINIKANTH et al., 2020; SETHY; BEHERA, 2022). Este tipo de combinação é nomeado como *ensemble learning* (HAGERTY et al., 2019; NANNI et al., 2020) e pode envolver também múltiplos algoritmos de classificação. Com isso, é possível ter uma decisão final única, mesmo considerando classificadores independentes, e mais precisa (NANNI et al., 2020; PONTI JR., 2011). O uso de *ensemble* de classificadores treinados com os atributos *handcrafted* e *deep learned* permitiu, por exemplo, concluir que os descritores *handcrafted* melhoraram o desempenho das classificações de células cervicais (NANNI et al., 2020). Outro destaque é o modelo apresentado por Hagerty et al. (2019), em que os autores realizaram um estudo comparativo entre o classificador (regressão logística) treinado somente com as carac-

terísticas *deep learned*, *ensemble* de atributos *handcrafted* e *ensemble* com todos os descritores. Os autores concluíram que o *ensemble* envolvendo todas as características indicaram as melhores taxas de distinções. No escopo de técnicas fractais e modelos de CNN, os autores Roberto et al. (2021) propuseram um *ensemble* entre duas arquiteturas CNN, uma treinada com imagens histológicas e a outra treinada com imagens artificiais, geradas a partir de características obtidas por meio de técnicas fractais. Os autores concluíram que a proposta superou as classificações obtidas pelos algoritmos de classificação e modelos CNN aplicados isoladamente.

Por fim, ainda é possível aplicar ao modelo de *ensemble learning* um estágio de seleção de atributos, com o intuito de reduzir o espaço de busca e aumentar a precisão do sistema, podendo ser realizado via seleção em uma fase (HASSAN et al., 2022; RIBEIRO et al., 2019), com a aplicação de um único seletor ou ainda, com a aplicação de duplo estágio de seleção, como abordado pelos autores (BHOWAL; SEN; SARKAR, 2021; CANDELERO et al., 2020; LI et al., 2022; ZHANG et al., 2018). A dupla seleção de atributos permite conhecer as principais composições para o desenvolvimento de sistemas CAD, tornando o conhecimento mais compreensível para os especialistas.

Esse trabalho está dividido em seis capítulos. No Capítulo 2 são apresentados os conceitos fundamentais para o entendimento do trabalho proposto. O Capítulo 3 aborda alguns dos trabalhos presentes na literatura, relacionados tanto com o tema abordado quanto com as técnicas propostas. No Capítulo 4 é introduzido a metodologia proposta e no Capítulo 5 é apresentado os resultados da aplicação do método proposto e uma discussão. Finalmente, no Capítulo 6 é dada uma breve conclusão do trabalho, algumas das contribuições e trabalhos futuros. O Apêndice A é composto por alguns resultados complementares.

Capítulo 6

Conclusão

Neste trabalho, foi proposto o *ensemble* de descritores *handcrafted* e *deep learned*, analisados mediante duplo estágio de seleção de atributos e classificados via *ensemble* de classificadores. O método foi aplicado para a tarefa de classificação de imagens histológicas H&E representativas de quatro categorias de imagens: câncer colorretal, tecidos hepáticos, tecidos orais e linfomas não-Hodgkin. Os descritores *handcrafted* foram obtidos via técnicas fractais multidimensionais e multiescala e atributos de textura LBP e Haralick. Quanto aos descritores *deep learned*, cinco arquiteturas CNN pré-treinadas no banco de imagens Imagenet, sem nenhum tipo de *fine-tuning*, foram utilizadas como extratores de atributos, sendo elas as arquiteturas ResNet-50, VGG-19, Inception v3, EfficientNet-B2 e DenseNet-121. O *ensemble* heterogêneo de classificadores foi composto pelos algoritmos SVM, KNN, *Random Forest*; Regressão Logística e *Naive Bayes*.

Os *ensembles* de descritores se mostraram superiores em relação às classificações somente por CNN, inclusive, em alguns casos, mais relevantes do que os conquistados com *ensembles* considerando somente *deep features*. A estratégia desenvolvida neste trabalho conseguiu fornecer valores de acurácias médias de 90,72% a 100%. Outra importante contribuição desse trabalho está relacionada com as principais soluções explorando um número reduzido de atributos. Considerando que o espaço inicial de

características é 11086 valores (462 descritores *handcrafted* com 10624 *deep learned*), a metodologia proposta conseguiu fornecer taxas de acurácias relevantes usando no máximo 53 características. Os destaques foram: CR com apenas 22 descritores via bGWO; OED com apenas 11 descritores via PSO; LA com 39 descritores via bGWO; LG com somente 29 atributos, bGWO; NHL com 53 descritores, GA.

Além disso, a metodologia proposta atingiu resultados competitivos em relação aos trabalhos que abordaram os mesmos contextos de imagens, fornecendo as principais combinações de técnicas para apoiar o desenvolvimento de sistemas CAD focados em analisar imagens histológicas H&E, especialmente representativas de câncer colorretal, tecido hepático, linfomas não-Hodgkin e displasia oral.

Em relação às limitações ou restrições enfrentadas pela aplicação do método, podemos elencar principalmente a questão dos algoritmos que utilizam algum tipo de hiperparâmetros. Uma vez que foram utilizados valores fixos de hiperparâmetros, pode haver a possibilidade deles não representarem os valores ideais na solução do contexto proposto, já que não foi realizada qualquer otimização neste quesito. Tais hiperparâmetros abrangem os métodos de extração de atributos *handcrafted* e os métodos de seleção de atributos: ponto de corte do algoritmo ReliefF e valores intrínsecos para a execução dos seletores *wrapper*.

Por fim, nosso trabalho proveu as seguintes contribuições: a construção e análise comparativa de *ensembles* baseados em múltiplas categorias de descritores *handcrafted* e *deep learned*; estruturação e aplicação do método de *ensemble learning* ainda não explorado no contexto H&E, composto por um duplo estágio de seleção de atributos e um *ensemble* heterogêneo de classificadores; comparação do método proposto frente às arquiteturas CNN treinadas para a tarefa de classificação das imagens em análise; conhecer alguns dos padrões de técnicas e atributos presentes nas melhores soluções para a classificação de imagens histológicas representativas do câncer colorretal, displasia oral, linfomas não-Hodgkin e tecidos hepáticos; obtenção de acurácias

competitivas frente aos trabalhos correlatos, com a vantagem de explorar um número reduzido de atributos.

Referências

ADEL, D.; MOUNIR, J.; EL-SHAFFEY, M.; ELDIN, Y. A.; MASRY, N. E.; ABDEL-RAOUF, A.; ELHAMID, I. S. A. Oral epithelial dysplasia computer aided diagnostic approach. In: . [S.l.]: Institute of Electrical and Electronics Engineers Inc., 2019. p. 313–318.

AGEMAP, N. I. o. A. The atlas of gene expression in mouse aging project (agemap). 2020. <https://ome.grc.nia.nih.gov/iicbu2008/agemap/index.html>. Online; acesso: 19-03-2020.

AGGARWAL, C. C. Data Classification: Algorithms and Applications. [S.l.]: Chapman & Hall/CRC, 2015. v. 1.

AHA, D. W. Lazy Learning. [S.l.]: Springer, 1997. v. 11.

AHMED, T.; SABAB, N. H. N. Classification and understanding of cloud structures via satellite images with efficientunet. 9 2020. Disponível em: <http://arxiv.org/abs/2009.12931>.

AHONEN, T.; HADID, A.; PIETIKÄINEN, M. Face recognition with local binary patterns. ECCV 2004: Computer Vision - ECCV 2004, Springer, v. 3021, p. 469–481, 2004.

AKBAR, B.; GOPI, V. P.; BABU, V. S. Colon cancer detection based on structural and statistical pattern recognition. 2015 2nd International Conference on Electronics and Communication Systems (ICECS), IEEE, p. 1735—1739, 2015.

AL-MASNI, M. A.; AL-ANTARI, M. A.; PARK, J. M.; GI, G.; KIM, T. Y.; RIVERA, P.; VALAREZO, E.; HAN, S. M.; KIM, T. S. Detection and classification of the breast abnormalities in digital mammograms via regional convolutional neural network. 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), IEEE, p. 1230–1233, 2017.

ALMARAZ-DAMIAN, J.-A.; PONOMARYOV, V.; SADOVNYCHIY, S.; CASTILLEJOS-FERNANDEZ, H. Melanoma and nevus skin lesion classification using handcraft and deep learning feature fusion via mutual information measures. Entropy, v. 22, n. 4, p. 484, 2020.

ALTUNBAY, D.; CIGIR, C.; SOKMENSUER, C.; GUNDUZ-DEMIR, C. Color graphs for automated cancer diagnosis and grading. IEEE Transactions on Biomedical Engineering, v. 57, n. 3, p. 665–674, 2010.

ANDREARCZYK, V.; WHELAN, P. F. Deep learning for biomedical texture image analysis. Proceedings of the Irish Machine Vision & Image Processing Conference. Irish Pattern Recognition & Classification Society (IPRCS), 2017.

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, v. 12, n. 6, p. e0177544, 2017.

AZARMEHR, N.; SHEPHARD, A.; MAHMOOD, H.; RAJPOOT, N.; KHURRAM, S. A. Automated oral epithelial dysplasia grading using neural networks and feature analysis. In: Medical Imaging with Deep Learning. [s.n.], 2022. Disponível em: <https://openreview.net/forum?id=ABl-dIO4g74>.

BAISH, J. W.; JAIN, R. K. Fractals and cancer. Cancer research, v. 60, n. 14, p. 3683–3688, 2000.

BEN HAMIDA, A.; DEVANNE, M.; WEBER, J.; TRUNTZER, C.; DERANGÈRE, V.; GHIRINGHELLI, F.; FORESTIER, G.; WEMMERT, C. Deep learning for colon cancer histopathological images analysis. Computers in Biology and Medicine, v. 136, p. 104730, 2021. ISSN 0010-4825. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0010482521005242>.

BHOWAL, P.; SEN, S.; SARKAR, R. A two-tier feature selection method using coalition game and nystrom sampling for screening covid-19 from chest x-ray images. Journal of Ambient Intelligence and Humanized Computing, 2021. Disponível em: <https://doi.org/10.1007/s12652-021-03491-4>.

BOUSSAÏD, I.; LEPAGNOT, J.; SIARRY, P. A survey on optimization metaheuristics. Information Sciences, Elsevier, v. 237, p. 82–117, 2013.

BRADLEY, A. P. The use of the area under the roc curve in the evaluation of machine learning algorithms. Pattern Recognition, v. 30, n. 7, p. 1145–1159, 1997.

BREIMAN, L. Random forests. Machine Learning, v. 45, n. 1, p. 5–32, 2001.

BROADBENT, S. R.; HAMMERSLEY, J. M. Percolation processes: I. crystals and mazes. Mathematical Proceedings of the Cambridge Philosophical Society, Cambridge University Press, v. 53, n. 3, p. 629–641, 1957.

BUDNIK, M.; GUTIERREZ-GOMEZ, E.; SAFADI, B.; PELLERIN, D.; QUÉNOT, G. Learned features versus engineered features for multimedia indexing. Multimedia Tools and Applications, Springer, v. 76, p. 11941–11958, 2017.

BUNDE, A.; HAVLIN, S. A brief introduction to fractal geometry. Fractals in Science, Springer Berlin Heidelberg, 1994.

CANDELERO, D.; ROBERTO, G. F.; NASCIMENTO, M. Z. do; ROZENDO, G. B.; NEVES, L. A. Selection of cnn, haralick and fractal features based on evolutionary algorithms for classification of histological images. In: 2020 IEEE International

Conference on Bioinformatics and Biomedicine (BIBM). [S.l.]: IEEE, 2020. p. 2709–2716.

CARUSO, D.; ZERUNIAN, M.; CIOLINA, M.; DE SANTIS, D.; RENGO, M.; SOMMRO, M. H.; GIUNTA, G.; CONFORTO, S.; SCHMID, M.; NERI, E.; LAGHI, A. Haralick's texture features for the prediction of response to therapy in colorectal cancer: a preliminary study. La radiologia medica, Springer, v. 123, p. 161–167, 2018.

CHAN, H. P.; HADJIISKI, L. M.; SAMALA, R. K. Computer-aided diagnosis in the era of deep learning. Med. Phys., v. 47, n. 5, p. e218–e227, 2020.

CHANDRASHEKAR, G.; SAHIN, F. A survey on feature selection methods. Computers and Electrical Engineering, v. 40, n. 1, p. 16–28, 2014.

CONNERS, R. W.; TRIVEDI, M. M.; HARLOW, C. A. Segmentation of a high-resolution urban scene using texture operators. Comp Vision Graphics Image Process, Elsevier, v. 25, n. 3, p. 273–310, 1984.

CUEVAS, E.; GONZALEZ, M.; ZALDIVAR, D.; PEREZ-CISNEROS, M.; GARCÍA, G. An algorithm for global optimization inspired by collective animal behavior. Discrete Dynamics in Nature and Society, v. 2012, p. 24, 2012.

CĂLIMAN A. ; IVANOVICI, M. Psoriasis image analysis using color lacunarity. 2012 13th International Conference on Optimization of Electrical and Electronic Equipment (OPTIM), IEEE, p. 1401–1406, 2012.

DEMŠAR, J. Statistical comparisons of classifiers over multiple data sets. Journal of Machine Learning Research, v. 7, p. 1–30, 2006. ISSN 15337928.

DEVOS, A. K.; van Huffel, S.; SIMONETTI, A. W.; GRAAF, M. v.; HEERSCHAP, A.; BUYDENS, L. M. C. Chapter 11 - classification of brain tumours by pattern recognition of magnetic resonance imaging and spectroscopic data. In: TAKTAK, A. F. G.; FISHER, A. C. (Ed.). Outcome Prediction in Cancer. [S.l.]: Elsevier, 2007. p. 285 – 318.

DORNAIKA, F.; BOSAGHZADEH, A.; SALMANE, H.; RUCHEK, Y. Chapter 9 - object categorization using adaptive graph-based semi-supervised learning. In: SAMUI, P.; SEKHAR, S.; BALAS, V. E. (Ed.). Handbook of Neural Computation. [S.l.]: Academic Press, 2017. p. 167–179. ISBN 978-0-12-811318-9.

DOSOVITSKIY, A.; BEYER, L.; KOLESNIKOV, A.; WEISSENBORN, D.; ZHAI, X.; UNTERTHINER, T.; DEGHANI, M.; MINDERER, M.; HEIGOLD, G.; GELLY, S.; USZKOREIT, J.; HOULSBY, N. An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. 2020. Disponível em: <http://arxiv.org/abs/2010.11929>.

EGER, S.; YOUSSEF, P.; GUREVYCH, I. Is it time to swish? comparing deep learning activation functions across nlp tasks. In: . [S.l.: s.n.], 2018. p. 4415–4424.

- ELGENDY, M. Advanced CNN Architectures. 2020. <https://livebook.manning.com/book/grokking-deep-learning-for-computer-vision/chapter-5/v-3/34>. Online; acesso: 30-10-2020.
- ELMANNAI, H.; HAMDI, M.; ALGARNI, A. Deep learning models combining for breast cancer histopathology image classification. International Journal of Computational Intelligence Systems, v. 14, n. 1, p. 1003–1013, 2021. ISSN 18756883.
- EMARYA, E.; ZAWBAAB, H. M.; HASSANIENA, A. E. Binary grey wolf optimization approaches for feature selection. Neurocomputing, Elsevier, p. 371–381, 2016.
- FAWCETT, F. An introduction to roc analysis. Pattern Recognition Letters, v. 27, n. 8, p. 861–874, 2006.
- FONDÓN, I.; SARMIENTO, A.; GARCÍA, A. I.; SILVESTRE, M.; ELOY, C.; POLÓNIA, A.; AGUIAR, P. Automatic classification of tissue malignancy for breast carcinoma diagnosis. Computers in Biology and Medicine, Elsevier, v. 96, n. 1, p. 41–51, 2018.
- FONTES, L. R. G. Notas em percolação. Instituto de Matemática Pura e Aplicada, 1996.
- FREUND, Y.; SCHAPIRE, R. E. Experiments with a new boosting algorithm. Proceedings of the 13th International Conference on Machine Learning, p. 148–156, 1996.
- GARTNER, L. P. Textbook of Histology. 5. ed. [S.l.]: Elsevier, 2020.
- GHOSH, S.; BANDYOPADHYAY, A.; SAHAY, S.; GHOSH, R.; KUNDU, I.; SANTOSH, K. C. Colorectal histology tumor detection using ensemble deep neural network. Engineering Applications of Artificial Intelligence, v. 100, p. 104202, 2021.
- GOMES, R. L.; VANDERLEI, L. C. M.; GARNER, D. M.; VANDERLEI, F. M.; VALENTI, V. E. Higuchi fractal analysis of heart rate variability is sensitive during recovery from exercise in physically active men. MedicalExpress, v. 4, n. 3, 2017.
- GOMOLKA, R. S.; KAMPUSCH, S.; KANIUSAS, E.; THÜRCK F. SZÉLES, J. C.; KLONOWSKI, W. Higuchi fractal dimension of heart rate variability during percutaneous auricular vagus nerve stimulation in healthy and diabetic subjects. Front. Physiol., v. 9, n. 1162, 2018.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep learning. MIT Press, 2016.
- GOOGLE. Colaboratory. 2021. Online; acesso: 20-07-2021. Disponível em: <https://research.google.com/colaboratory/faq.html>.
- GRANIK, M.; MESYURA, V. Fake news detection using naive bayes classifier. In: 2017 IEEE First Ukraine Conference on Electrical and Computer Engineering (UKRCON). [S.l.: s.n.], 2017. p. 900–903.

GREENSPAN, H.; GINNEKEN, B.; SUMMERS, R. M. Guest editorial deep learning in medical imaging: Overview and future promise of an exciting new technique. IEEE Transactions on Medical Imaging, IEEE, v. 35, n. 5, p. 1153 – 1159, 2016.

HAGERTY, J. R.; STANLEY, R. J.; ALMUBARAK, H. A.; LAMA, N.; KASMI, R.; GUO, P.; DRUGGE, R. J.; RABINOVITZ, H. S.; OLIVIERO, M.; STOECKER, W. V. Deep learning and handcrafted method fusion: Higher diagnostic accuracy for melanoma dermoscopy images. IEEE Journal of Biomedical and Health Informatics, IEEE, v. 23, n. 4, p. 1385–1391, 2019.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The weka data mining software: an update. ACM SIGKDD explorations newsletter, ACM, v. 11, n. 1, p. 10–18, 2009.

HAQUE, I. R. I.; NEUBERT, J. Deep learning approaches to biomedical image segmentation. Informatics in Medicine Unlocked, Elsevier, v. 18, p. 100297, 2020.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. IEEE Transactions on Systems, Man, and Cybernetics, IEEE, SMC-3, n. 6, p. 610 – 621, 1973.

HARRIS, J. W.; STOCKER, H. Handbook of Mathematics and Computational Science. [S.l.]: Springer, 1998.

HASSAN, A. H.; WAHED, M. E.; ATIEA, M. A.; METWALLY, M. S. A hybrid approach for classification breast cancer histopathology images. Frontiers in Scientific Research and Technology, Suez University, Faculty of Science, v. 3, n. 1, p. 1–10, 2022. ISSN 2682-2962.

HE, K.; ZHANG, X.; REN, S.; SUN, J. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. Proceedings of the IEEE International Conference on Computer Vision (ICCV), IEEE, p. 1026–1034, 2015.

HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, p. 770–778, 2016.

HIGUCHI, T. Approach to an irregular time series on the basis of the fractal theory. Physica D: Nonlinear Phenomena, Elsevier, v. 31, n. 2, p. 227–283, 1988.

HSU, H.; HSIEH, C. W.; LU, M. Hybrid feature selection by combining filters and wrappers. Expert Systems with Applications, v. 38, n. 7, p. 8144–8150, 2011.

HUANG, G.; LIU, Z.; MAATEN, L.; WEINBERGER, K. Q. Densely connected convolutional networks. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), p. 2261–2269, 2017.

IDE, H.; KURITA, T. Improvement of learning for cnn with relu activation by sparse regularization. 2017 International Joint Conference on Neural Networks (IJCNN), IEEE, p. 2684–2691, 2017.

IFTIKHAR, A. Feature selection using particle swarm optimization in intrusion detection. International Journal of Distributed Sensor Networks, v. 2015, p. 1–8, 2015.

IFTIKHAR, M. A.; HASSAN, M.; ALQUHAYZ, H. A colon cancer grade prediction model using texture and statistical features, smote and mrmr. 2016 19th International Multi-Topic Conference (INMIC), IEEE, p. 1–7, 2016.

IVANOVICI, M.; RICHARD, N. The lacunarity of colour fractal images. In: Proceedings of the 16th IEEE international conference on image processing (ICIP), IEEE, p. 453–456, 2009.

IVANOVICI, M.; RICHARD, N. Fractal dimension of color fractal images, image processing. IEEE Transactions on Image Processing, IEEE, v. 20, n. 1, p. 227–235, 2011.

IVANOVICI, M.; RICHARD, N.; DECEAN, H. Fractal dimension and lacunarity of psoriatic lesions—a colour approach—. Proceedings of the 2nd WSEAS International Conference on Biomedical Electronics and Biomedical Informatics, BEBI '09, v. 6, 2009.

JASTI, V. D. P.; ZAMANI, A. S.; ARUMUGAM, K.; NAVED, M.; PALLATHADKA, H.; SAMMY, F.; RAGHUVANSHI, A.; KALIYAPERUMAL, K. Computational technique based on machine learning and image processing for medical image analysis of breast cancer diagnosis. Security and Communication Networks, 2022. Disponível em: <https://doi.org/10.1155/2022/1918379>.

JIANG, L.; CAI, Z.; WANG, D.; JIANG, S. Survey of improving k-nearest-neighbor for classification. In: Fourth International Conference on Fuzzy Systems and Knowledge Discovery (FSKD 2007). [S.l.: s.n.], 2007. v. 1, p. 679–683.

JUNQUEIRA, L. C.; CARNEIRO, J. Histologia Básica: Texto & Atlas. 12. ed. [S.l.]: Guanabara Koogan, 2013.

JØRGENSEN, A.; RASMUSSEN, A. M.; ANDERSEN, N. K. M.; ANDERSEN, S. K.; EMBORG, J.; RØGE, R.; ØSTERGAARD, L. Using cell nuclei features to detect colon cancer tissue in hematoxylin and eosin stained slides. Cytometry Part A, Wiley Online Library, 2017.

KALRA, S.; TIZHOOSH, H. R.; CHOI, C.; SHAH, S.; DIAMANDIS, P.; CAMPBELL, C. J. V.; PANTANOWITZ, L. Yottixel – an image search engine for large archives of histopathology whole slide images. Medical Image Analysis, v. 65, p. 101757, 2020. ISSN 1361-8415.

KANTARCIOGLU, M.; VAIDYA, J. Privacy-preserving naive bayes classifier for horizontally partitioned data. IEEE Workshop on Privacy-Preserving Data Mining, IEEE, 2003.

KARSMAKERS, P.; PELCKMANS, K.; SUYKENS, J. A. K. Multi-class kernel logistic regression: a fixed-size implementation. In: 2007 International Joint Conference on Neural Networks. [S.l.: s.n.], 2007. p. 1756–1761.

KASSANI, S. H.; KASSANI, P. H.; WESOLOWSKI, M. J.; SCHNEIDER, K. A.; DETERS, R. Classification of histopathological biopsy images using ensemble of deep learning networks. CASCON '19: Proceedings of the 29th Annual International Conference on Computer Science and Software Engineering, p. 92–99, 2019.

KATHER, J. N.; WEIS, C.; BIANCONI, F.; MELCHERS, S. M.; SCHAD, L. R.; GAISER, T.; MARX, A.; ZOELLNER, F. G. Multi-class texture analysis in colorectal cancer histology. Scientific Reports, v. 6, 2016.

KENNEDY, J.; EBERHART, R. Particle swarm optimization. Proceedings of ICNN'95 - International Conference on Neural Networks, IEEE, v. 4, p. 1942–1948, 1995.

KLONOWSKI, W.; PIERZCHALSKI, M.; STEPIEN, P.; STEPIEN, R.; AHAMMER, H. Application of Higuchi's fractal dimension in analysis of images of anal intraepithelial neoplasia. Chaos, Solitons & Fractals, Elsevier, v. 48, p. 54–60, 2013.

KLONOWSKI, W.; STEPIEN, P.; STEPIEN, R.; SEDIVY, R.; AHAMMER, H.; SPASIC, S. Analysis of anal intraepithelial neoplasia images using 1d and 2d Higuchi's fractal dimension methods. Fractals, World Scientific Publishing Company, v. 26, n. 3, 2018.

KORKMAZ, S. A.; BINOL, H. Classification of molecular structure images by using ann, rf, lbp, hog, and size reduction methods for early stomach cancer detection. Journal of Molecular Structure, v. 1156, p. 255–263, 2018.

KOTSIANTIS, S. B. Feature selection for machine learning classification problems: a recent overview. Artificial Intelligence Review, Springer, v. 41, 2011.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: PEREIRA, F.; BURGESS, C. J. C.; BOTTOU, L.; WEINBERGER, K. Q. (Ed.). Advances in Neural Information Processing Systems 25. [S.l.]: Curran Associates, Inc., 2012. p. 1097–1105.

KULKARNI, U.; MEENA, S. M.; GURLAHOSUR, S. V.; MUDENGUDI, U. Classification of cultural heritage sites using transfer learning. 2019 IEEE Fifth International Conference on Multimedia Big Data (BigMM), IEEE, p. 391–397, 2019.

KUMAR, A.; BI, L.; KIM, J.; FENG, D. D. Chapter five - machine learning in medical imaging. In: FENG, D. D. (Ed.). Biomedical Information Technology. 2. ed. [S.l.]: Elsevier, 2020. p. 167–196.

KUMAR, N.; SHARMA, M.; SINGH, V. P.; MADAN, C.; MEHANDIA, S. An empirical study of handcrafted and dense feature extraction techniques for lung and colon cancer classification from histopathological images. Biomedical Signal Processing and Control, Elsevier Ltd, v. 75, n. 75, p. 103596, 2022. ISSN 17468108. Disponível em: <https://doi.org/10.1016/j.bspc.2022.103596>.

- KUNCHEVA, L. I. Combining classifiers: soft computing solutions. In: Pattern Recognition. [S.l.: s.n.], 2001. p. 427–451.
- KUNCHEVA, L. I.; BEZDEK, J. C.; DUIN, R. P. W. Decision templates for multiple classifier fusion: an experimental comparison. Pattern Recognition, v. 34, n. 2, p. 299 – 314, 2001.
- KURT, I.; TURE, M.; KURUM, A. T. Comparing performances of logistic regression, classification and regression tree, and neural networks for predicting coronary artery disease. Expert Systems with Applications, v. 34, n. 1, p. 366 – 374, 2008.
- KWASIGROCH, A.; MIKOŁAJCZYK, A.; GROCHOWSKI, M. Deep neural networks approach to skin lesions classification — a comparative analysis. In: 2017 22nd International Conference on Methods and Models in Automation and Robotics (MMAR). [S.l.]: IEEE, 2017. p. 1069–1074.
- LAHDENOJA, O.; POIKONEN J. ANTD LAIHO, M. Towards understanding the formation of uniform local binary patterns. ISRN Machine Vision, v. 2013, 07 2013.
- LAWRENCE, S.; GILES, C. L.; TSOI, A. C.; BACK, A. D. Face recognition: A convolutional neural-network approach. IEEE Transactions on Neural Networks, IEEE, v. 8, n. 1, p. 98–113, 1997.
- LE, T. T.; URBANOWICZ, R. J.; MOORE, J. H.; MCKINNEY, B. A. Statistical inference relief (stir) feature selection. Bioinformatics, v. 35, n. 8, p. 1358–1365, 2019.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. Nature, Macmillan Publishers Limited, v. 521, n. 7553, p. 436–444, 2015.
- LI, L.; CHANG, L.; KE, S.; HUANG, D. Multifractal analysis and lacunarity analysis: A promising method for the automated assessment of muskmelon (cucumis melol.) epidermis netting. Computers and Electronics in Agriculture, Elsevier, v. 88, p. 72–84, 2012.
- LI, X.; SHEN, X.; ZHOU, Y.; WANG, X.; LI, T. Q. Classification of breast cancer histopathological images using interleaved densenet with senet (idsnet). PLoS ONE, Public Library of Science, v. 15, 5 2020.
- LI, X.; WU, J.; JIANG, H.; CHEN, E. Z.; DONG, X.; RONG, R. Skin lesion classification via combining deep learning features and clinical criteria representations. bioRxiv, Cold Spring Harbor Laboratory, 2018.
- LI, Y.; SHEN, Y.; FAN, X.; HUANG, X.; YU, H.; ZHAO, G.; MA, W. A novel EEG-based major depressive disorder detection framework with two-stage feature selection. BMC Medical Informatics and Decision Making, v. 22, n. 209, 2022. Disponível em: <https://doi.org/10.1186/s12911-022-01956-w>.
- LIEPINS, G. E.; VOSE, M. D. Representational issues in genetic optimization. Journal of Experimental & Theoretical Artificial Intelligence, Taylor & Francis, v. 2, n. 2, p. 101–115, 1990.

LITJENS, G.; KOOI, T.; BEJNORDI, B. E.; SETIO, A. A. A.; CIOMPI, F.; GHAFORIAN, M.; LAAK, J. A. W. M. van der; GINNEKEN B. SÁNCHEZ, C. I. A survey on deep learning in medical image analysis. Medical Image Analysis, Elsevier, v. 42, p. 60–88, 2017.

LOPES, R.; BETROUNI, N. Fractal and multifractal analysis: a review. Medical image analysis, Elsevier, v. 13, n. 4, p. 634–649, 2009.

MAHMOOD, A.; GIRALDO, A.; BENNAMOUN, M.; AN, S.; SOHEL, F.; BOUSSAID, F.; HOVEY, R.; FISHER, R.; KENDRICK, G. Automatic hierarchical classification of kelps using deep residual features. Sensors, v. 20, p. 447, 01 2020.

MANDELBROT, B. The Fractal Geometry of Nature. [S.l.]: Freeman, 1983.

MANDELBROT, B. B. Fractals: Form, chance and dimension. M. San Francisco: Freeman, 1977.

MATHWORKS. R2019a at a Glance. 2021. Online; acesso: 20-07-2021. Disponível em: <https://ch.mathworks.com/solutions/deep-learning/models.html>.

MATHWORKS. Extract local binary pattern (LBP) features. c2022. <https://www.mathworks.com/help/vision/ref/extractlbpfeatures.html#buumhti-1-CellSize>. Online; acesso: 18-05-2022.

MAZO, C.; ALEGRE, E.; TRUJILLO, M. Classification of cardiovascular tissues using lbp based descriptors and a cascade svm. Computer Methods and Programs in Biomedicine, Elsevier, v. 147, p. 1–10, 2017.

MENGDI, L.; LIANCHENG, X.; JING, Y.; JIE, H. A feature gene selection method based on relieff and pso. In: 2018 10th International Conference on Measuring Technology and Mechatronics Automation (ICMTMA). [S.l.]: IEEE, 2018. p. 298–301.

MIYAMOTO, Y.; MERRYMAN, T. E. Fast calculation of haralick texture features. Technical Report, 2005.

MUNIEN, C.; VIRIRI, S. Classification of hematoxylin and eosin-stained breast cancer histology microscopy images using transfer learning with efficientnets. Computational Intelligence and Neuroscience, v. 2021, p. 1–17, 04 2021.

NANNI, L.; BRAHNAM, S.; GHIDONI, S.; MAGUOLO, G. General purpose (genp) bioimage ensemble of handcrafted and learned features with data augmentation. CoRR, abs/1904.08084, 2019.

NANNI, L.; GHIDONI, S.; BRAHNAM, S. Handcrafted vs. non-handcrafted features for computer vision classification. Pattern Recognition, Elsevier, v. 71, p. 158–172, 2017.

NANNI, L.; GHIDONI, S.; BRAHNAME, S. Ensemble of convolutional neural networks for bioimage classification. Applied Computing and Informatics, Elsevier, 2018.

NANNI, L.; GHIDONI, S.; BRAHNAME, S.; LIU, S.; ZHANG, L. Ensemble of hand-crafted and deep learned features for cervical cell classification. In: NANNI, L.; BRAHNAME, S.; BRATTIN, R.; GHIDONI, S.; JAIN, L. (Ed.). Deep Learners and Deep Learner Descriptors for Medical Applications. Intelligent Systems Reference Library. [S.l.]: Springer, 2020. v. 186, p. 117–135.

NAYAK, S. R.; MISHRA, J. An improved method to estimate the fractal dimension of colour images. Perspectives in Science, Elsevier, v. 8, p. 412–416, 2016.

NEVES, L. A.; NASCIMENTO, M. do; OLIVEIRA, D. L.; MARTINS, A. S.; GODOY, M. F.; ARRUDA, P. F.; NETO, D. d. S.; MACHADO, J. M. Multi-scale lacunarity as an alternative to quantify and diagnose the behavior of prostate cancer. Expert Systems with Applications, Elsevier, v. 41, n. 11, p. 5017–5029, 2014.

NGUYEN, H.-T.; VU, N. S.; CAPLIER, A. How far we can improve micro features based face recognition systems? In: . [S.l.: s.n.], 2012. p. 350–353.

NIKOLAIDIS, N. S.; NIKOLAIDIS, I. N.; TSOUROU, C. C. A variation of the box-counting algorithm applied to colour images. arXiv preprint arXiv:1107.2336, 2011.

NKETIAH, G.; ELSCHOT, M.; KIM, E.; TERUEL, J. R.; SCHEENEN, T. W.; BATHEN, T. F.; SELNÆS, K. M. T2-weighted mri-derived textural features reflect prostate cancer aggressiveness: preliminary results. Eur Radiol, Springer, v. 27, p. 3050–3059, 2017.

NWANKPA, C.; IJOMAH, W.; GACHAGAN, A.; MARSHALL, S. Activation functions: Comparison of trends in practice and research for deep learning. ArXiv, abs/1811.03378, 2018.

OHATA, E. F.; DAS CHAGAS, J. V. S.; BEZERRA, G. M.; HASSAN, M. M.; DE ALBUQUERQUE, V. H. C.; FILHO, P. P. R. A novel transfer learning approach for the classification of histological images of colorectal cancer. The Journal of Supercomputing, Springer US, v. 77, p. 9494–9519, 2021. ISSN 15730484.

OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on featured distributions. Pattern Recognition, v. 29, n. 1, p. 51–59, 1996.

PACHECO, M. A. C. Algoritmos Genéticos: Princípios e Aplicações. Apostila de Aula. Versão 1. Pontifícia Universidade Católica do Rio de Janeiro, ICA: Laboratório de Inteligência Computacional Aplicada. 1999. <http://www2.ica.ele.puc-rio.br/Downloads/38/CE-Apostila-Comp-Evol.pdf/>. Online; acesso: 2019-04-11.

PAN, S. J.; YANG, Q. A survey on transfer learning. IEEE Transactions on Knowledge and Data Engineering, v. 22, n. 10, p. 1345–1359, 2010.

PARMANTO, B. A.; MUNRO, P. W.; DOYLE, H. R. Improving committee diagnosis with resampling techniques. In: TOURETZKY, D. S.; MOZER, M. C.; HASSELMO, M. E. (Ed.). Advances in Neural Information Processing Systems. [S.l.]: MIT Press, 1996. p. 882–888.

PEDRINI, H.; SCHWARTZ, W. R. Análise de imagens digitais: Princípios, algoritmos e aplicações. 1. ed. [S.l.]: Cengage, 2008. v. 1.

PENTLAND, A. Fractal-based description of natural scenes. IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-6, n. 6, p. 661–674, 1984.

PLOTNICK, R. E.; GARDNER, R. H.; O'NEIL, R. V. Lacunarity indices as measures of landscape texture. Landscape Ecology, SPB Academic Publishing, v. 8, n. 3, p. 201–211, 1993.

PONTI JR., M. P. Combining classifiers: From the creation of ensembles to the decision fusion. In: 2011 24th SIBGRAPI Conference on Graphics, Patterns, and Images Tutorials. [S.l.: s.n.], 2011. p. 1–10.

PONTI, M. P.; PAPA, J. P. Improving accuracy and speed of optimum-path forest classifier using combination of disjoint training subsets. In: SANSONE, C.; KITTLER, J.; ROLI, F. (Ed.). Multiple Classifier Systems. [S.l.]: Springer Berlin Heidelberg, 2011. p. 237–248.

PYTORCH. Pytorch. 2021. Online; acesso: 20-07-2021. Disponível em: <https://pytorch.org/>.

PYTORCH. Models and Pre-trained Weights. 2022. Online; acesso: 25-09-2022. Disponível em: <https://pytorch.org/vision/stable/models.html>.

RADWAN, N. Leveraging sparse and dense features for reliable state estimation in urban environments. In: . [S.l.: s.n.], 2019.

RAJINIKANTH, V.; RAJ, A. J.; THANARAJ, K.; NAIK, G. A customized vgg19 network with concatenation of deep and handcrafted features for brain tumor detection. Appl. Sci., v. 10, n. 10, p. 3429, 2020.

RAKHLIN, A.; SHVETS, A.; IGLOVIKOV, V.; KALININ, A. A. Deep convolutional neural networks for breast cancer histology image analysis. Image Analysis and Recognition. ICIAR 2018, Springer, v. 10882, p. 737–744, 2018.

RAMANESWARAN, S.; SRINIVASAN, K.; VINCENT, P. M. D. R.; CHANG, C. Hybrid inception v3 xgboost model for acute lymphoblastic leukemia classification. Computational and Mathematical Methods in Medicine, v. 2021, p. 1–10, 07 2021.

REZVANTALAB, A.; SAFIGHOLI, H.; KARIMIJEHNI, S. Dermatologist level dermatology skin cancer classification using different deep learning convolutional neural networks algorithms. arXiv:1810.10348, 2018.

RIBEIRO, M. G.; NEVES, L. A.; NASCIMENTO, M. Z. d.; ROBERTO, G. F.; MARTINS, A. M.; 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.

ROBERTO, G. F.; LUMINI, A.; NEVES, L. A.; NASCIMENTO, M. Z. Fractal neural network: A new ensemble of fractal geometry and convolutional neural networks for the classification of histology images. Expert Systems With Applications, Elsevier, v. 166, p. 114103, 2021.

ROBERTO, G. F.; NASCIMENTO, M. Z.; MARTINS, A. S.; TOSTA, T. A. A.; FARIA, P. R.; NEVES, L. A. Classification of breast and colorectal tumors based on percolation of color normalized images. Computers & Graphics, Elsevier, v. 84, p. 134–143, 2019.

ROBERTO, G. F.; NEVES, L. A.; NASCIMENTO, M. Z.; TOSTA, T. A. A.; LONGO, L. C.; MARTINS, A. S.; FARIA, P. R. Features based on the percolation theory for quantification of non-hodgkin lymphomas. Computers in Biology and Medicine, Elsevier, v. 91, p. 135–147, 2017.

ROBNIK ŠIKONJA, M.; KONONENKO, I. Theoretical and empirical analysis of relief and relief. Machine Learning, Kluwer Academic Publishers, v. 53, p. 23–69, 2003.

RUSSAKOVSKY, O.; DENG, J.; SU, H.; KRAUSE, J.; SATHEESH, S.; MASIHUANG, Z. Imagenet large scale visual recognition challenge. International Journal of Computer Vision, Springer, v. 115, p. 211–252, 2015.

SANTOS, F. P. dos; PONTI, M. S. Alignment of local and global features from multiple layers of convolutional neural network for image classification. In: 2019 32nd SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI). [S.l.]: IEEE, 2019. p. 241–248.

SEN, S.; SAHA, S.; CHATTERJEE, S.; MIRJALILI, S.; SARKAR, R. A bi-stage feature selection approach for covid-19 prediction using chest ct images. Applied Intelligence, v. 51, p. 8985–9000, 2021. Disponível em: <https://doi.org/10.1007/s10489-021-02292-8>.

SETHY, P. K.; BEHERA, S. K. Automatic classification with concatenation of deep and handcrafted features of histological images for breast carcinoma diagnosis. Multimedia Tools and Applications, Springer US, v. 81, p. 9631–9643, 2022.

SHAMIR, L.; ORLOV, N.; ECKLEY, D. M.; MACURA, T. J.; GOLDBERG, I. G. IICBU 2008: a proposed benchmark suite for biological image analysis. Med Biol Eng Comput, Springer, v. 46, n. 9, p. 943–947, 2008.

SHARMA, S.; KUMAR, S. The Xception model: A potential feature extractor in breast cancer histology images classification. ICT Express, Elsevier B.V., v. 8, n. 1, p.

101–108, 2022. ISSN 24059595. Disponível em: <https://doi.org/10.1016/j.ict.2021.11.010>.

SHEN, D.; WU, G.; SUK, H. Deep learning in medical image analysis. Annual Review of Biomedical Engineering, v. 19, n. 1, p. 221–248, 2017.

SIEGEL, R. L.; MILLER, K. D.; FUCHS, H. E.; JEMAL, A. Cancer statistics, 2021. CA: a cancer journal for clinicians, v. 71, n. 1, p. 7–33, 2021.

SILVA, A. B.; MARTINS, A. S.; TOSTA, T. A. A.; NEVES, L. A.; SERVATO, J. P. S.; de Araújo, M. S.; DE FARIA, P. R.; DO NASCIMENTO, M. Z. Computational analysis of histological images from hematoxylin and eosin-stained oral epithelial dysplasia tissue sections. Expert Systems with Applications, Elsevier Ltd, v. 193, 5 2022. ISSN 09574174.

SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. arXiv:1409.1556, 2014.

SIQUEIRA, F. R.; SCHWARTZ W. R. ANS PEDRINI, H. Multi-scale gray level co-occurrence matrices for texture description. Neurocomputing, Elsevier, v. 120, p. 336–345, 2013.

SIRINUKUNWATTANA, K.; PLUIM, J. P. W.; CHEN, H.; X., Q. Gland segmentation in colon histology images: The glas challenge contest. MedicalImageAnalysis, v. 35, p. 489–502, 2017.

SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. Information Processing and Management, Elsevier, v. 45, p. 427–437, 2009.

SPANHOL, F. A.; CAVALIN, P. R.; OLIVEIRA, L. S.; PETITJEAN, C.; HEUTTE, L. Deep features for breast cancer histopathological image classification. 2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC), IEEE, p. 1868–1873, 2017.

STRELNIKER, Y. M.; HAVLIN, S.; BUNDE, A. Fractals and percolation. Encyclopedia of Complexity and Systems Science, Springer New York, p. 3847–3858, 2009.

SZEGEDY, C.; LIU, W.; JIA, Y.; SERMANET, P.; REED, S.; ANGUELOV, D.; ERHAN, D.; VANHOUCHE, V.; RABINOVICH, A. Going deeper with convolutions. In: 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). [S.l.: s.n.], 2015. p. 1–9.

SZEGEDY, C.; VANHOUCHE, V.; IOFFE, S.; SHLENS, J.; WOJNA, Z. Rethinking the inception architecture for computer vision. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 12 2015.

TAINO, D. T.; RIBEIRO, M. G.; ROBERTO, G. F.; ZAFALON, G. F. D.; DO NASCIMENTO, M. Z.; TOSTA, T. A. A.; MARTINS, A. S.; NEVES, L. A. Analysis of cancer in histological images: employing an approach based on genetic algorithm. Pattern Analysis and Applications, Springer Science and Business Media Deutschland GmbH, v. 24, p. 483–496, 5 2021. ISSN 1433755X.

TALO, M. Convolutional neural networks for multi-class histopathology image classification. ArXiv, abs/1903.10035, 2019.

TAN, M.; LE, Q. V. Efficientnet: Rethinking model scaling for convolutional neural networks. Proceedings of the 36th International Conference on Machine Learning, PMLR, v. 97, p. 6105–6114, 2019.

TANG, J.; RANGAYYAN, R. M.; XU, J.; NAQA, I. E.; YANG, Y. Computer-aided detection and diagnosis of breast cancer with mammography: Recent advances. IEEE Transactions on Information Technology in Biomedicine, IEEE, v. 13, n. 2, p. 236–251, 2009.

TENGUAM, J. J.; LONGO, L. H. D. C.; SILVA, A. B.; FARIA, P. R.; NASCIMENTO, M. Z.; NEVES, L. A. Classification of H&E images exploring ensemble learning with two-stage feature selection. CFP2255E-ART, p. 1–4, 2022.

TENGUAM, J. J.; ROZENDO, G. B.; ROBERTO, G. F.; NASCIMENTO, M. Z.; MARTINS, A. S.; NEVES, L. A. Multidimensional and multiscale higuchi dimension for the analysis of colorectal histological images. 2020 IEEE International Conference on Bioinformatics and Biomedicine (BIBM), IEEE, v. 1, p. 2833–2839, 2020.

TESAR, L.; SHIMIZU, A.; SMUTEK, D.; KOBATAKE, H.; NAWANO, S. Medical image analysis of 3d ct images based on extension of haralick texture features. Comput Med Imaging Graph., v. 32, n. 6, p. 513–520, 2008.

TORREY, L.; SHAVLIK, J. Transfer learning. In: SORIA, E.; MARTIN, J.; MAGDALENA, R.; MARTINEZ, M.; SERRANO, A. (Ed.). Handbook of Research on Machine Learning Applications. [S.l.: s.n.], 2009.

TRIPATHI, S.; SINGH, S. H. Ensembling handcrafted features with deep features: an analytical study for classification of routine colon cancer histopathological nuclei images. Multimedia Tools and Applications, Springer, 2020.

URBANOWICZ, R. J.; MEEKER, M.; La Cava, W.; OLSON, R. S.; MOORE, J. H. Relief-based feature selection: Introduction and review. Journal of Biomedical Informatics, v. 85, p. 189–203, 2018.

VARLEY, T. F.; CRAIG, M.; ADAPA, R.; FINOIA, P.; WILLIAMS, G.; ALLANSON, J.; PICKARD, J.; MENON, D. K.; STAMATAKIS, E. A. Fractal dimension of cortical functional connectivity networks & severity of disorders of consciousness. PLoS One, v. 15, n. 2, p. e0223812, 2020.

WAH, B. Wiley Encyclopedia of Computer Science and Engineering. [S.l.]: John Wiley & Sons, 2008. v. 5.

WANG, C.; YU, C. Automated morphological classification of lung cancer subtypes using h&e tissue images. Machine Vision and Applications, Springer, v. 24, p. 1383–1391, 2013.

WANG, Y.; ACS, B.; ROBERTSON, S.; LIU, B.; SOLORZANO, L.; WÄHLBY, C.; HARTMAN, J.; RANTALAINEN, M. Improved breast cancer histological grading using deep learning. Annals of Oncology, Elsevier Ltd, v. 33, n. 1, p. 89–98, jan 2022. ISSN 15698041.

WATANABE, K.; KOBAYASHI, T.; WADA, T. Semi-supervised feature transformation for tissue image classification. PLoS ONE, v. 11, n. 12, p. 1–20, 2016. ISSN 19326203.

WIBMER, A.; HRICAK, H.; GONDO, T.; MATSUMOTO, K.; VEERARAGHAVAN, H.; FEHR, D.; ZHENG, J.; GOLDMAN, D.; MOSKOWITZ, C.; FINE, S. W.; REUTER, V. E.; EASTHAM, J.; SALA, E.; VARGAS, H. A. Haralick texture analysis of prostate mri: utility for differentiating non-cancerous prostate from prostate cancer and differentiating prostate cancers with different gleason scores. European Radiology, Elsevier, v. 25, p. 2840–2850, 2015.

WILL, C. Does pooling in convolutional networks actually work? 2018. <https://principlesofdeeplearning.com/index.php/2018/08/27/is-pooling-dead-in-convolutional-networks/>. Online; acesso: 04-10-2020.

WOLFRAM. Wolfram Neural Net Repository. c2022. <https://resources.wolframcloud.com/NeuralNetRepository/>. Online; acesso: 18-08-2022.

XIA, R.; ZONG, C.; LI, S. Ensemble of feature sets and classification algorithms for sentiment classification. Information Sciences, v. 181, n. 6, p. 1138 – 1152, 2011.

XUE, B.; ZHANG, M.; BROWNE, W. N. Particle swarm optimisation for feature selection in classification: novel initialisation and updating mechanisms. Applied Soft Computing, Elsevier, v. 18, p. 261–276, 2014.

YAMAGUCHI, T.; HASHIMOTO, S. Fast crack detection method for large-size concrete surface images using percolation-based image processing. Machine Vision and Applications, v. 21, p. 797–809, 2010.

YU, C.; CHEN, H.; LI, Y.; PENG, Y.; LI, J.; YANG, F. Breast cancer classification in pathological images based on hybrid features. Multimed Tools Appl, v. 78, p. 21325–21345, 2019.

ZHANG, X.; ZHANG, Q.; CHEN, M.; SUN, Y.; QIN, X.; LI, H. A two-stage feature selection and intelligent fault diagnosis method for rotating machinery using hybrid filter and wrapper method. Neurocomputing, Elsevier, v. 275, p. 2426–2439, 2018. ISSN 0925-2312.

ZHAO, X.; LI, D.; YANG, B.; CHEN, H.; YANG, X.; YU, C.; LIU, S. A two-stage feature selection method with its application. Computers and Electrical Engineering, Elsevier Ltd., v. 47, p. 114–125, 2015. ISSN 00457906. Disponível em: <http://dx.doi.org/10.1016/j.compeleceng.2015.08.011>.

ZHENG, Y.; YANG, C.; MERKULOV, A. Breast cancer screening using convolutional neural network and follow-up digital mammography. In: MAHALANOBIS, A.; ASHOK, A.; TIAN, L.; PETRUCCELLI, J. C. (Ed.). Computational Imaging III. SPIE, 2018. v. 10669, p. 1 – 13. Disponível em: <https://doi.org/10.1117/12.2304564>.

Apêndice A

Resultados Obtidos

Tabela A.1: Acurácias e outras informações complementares obtidas nos 10 testes executados para cada combinação *ensemble* de descritores + seletor *wrapper* no *dataset* CR.

Seletor Execução	PSO			GA			bGWO		
	HF	DL	HF+DL	HF	DL	HF+DL	HF	DL	HF+DL
1	90,91%	98,79%	99,39%	93,94%	100%	98,79%	92,73%	100%	99,39%
2	92,73%	100%	99,39%	90,91%	98,18%	98,79%	94,55%	100%	99,39%
3	93,94%	100%	98,79%	90,91%	98,79%	99,39%	90,91%	100%	99,39%
4	90,91%	99,39%	99,39%	90,91%	99,39%	100%	92,12%	99,39%	99,39%
5	93,94%	98,79%	100%	90,30%	98,18%	100%	91,52%	100%	98,79%
6	91,52%	98,79%	100%	93,33%	98,79%	98,79%	92,12%	99,39%	99,39%
7	92,73%	100%	99,39%	93,33%	98,79%	99,39%	93,33%	100%	100%
8	90,30%	99,39%	100%	88,48%	100%	100%	89,70%	99,39%	100%
9	92,12%	100%	100%	89,70%	100%	100%	92,73%	99,39%	99,39%
10	90,30%	99,39%	99,39%	92,12%	99,39%	99,39%	93,33%	100%	99,39%
Média	91,94%	99,45%	99,58%	91,39%	99,15%	99,45%	92,30%	99,76%	99,45%
Desvio Padrão	1,30%	0,50%	0,39%	1,67%	0,67%	0,50%	1,30%	0,30%	0,33%
Melhor acurácia	93,94%	100%	100%	93,94%	100%	100%	94,55%	100%	100%

Tabela A.2: Acurácias e outras informações complementares obtidas nos 10 testes executados para cada combinação *ensemble* de descritores + seletor *wrapper* no *dataset* OED.

Seletor Execução	PSO			GA			bGWO		
	HF	DL	HF+DL	HF	DL	HF+DL	HF	DL	HF+DL
1	100%	97,97%	96,62%	98,65%	96,62%	96,62%	99,32%	96,62%	99,32%
2	100%	96,62%	99,32%	99,32%	97,97%	99,32%	99,32%	98,65%	99,32%
3	100%	95,95%	98,65%	100%	98,65%	99,32%	100%	97,97%	97,97%
4	100%	96,62%	99,32%	99,32%	97,97%	99,32%	100%	97,97%	99,32%
5	100%	97,30%	98,65%	99,32%	97,30%	100%	100%	96,62%	99,32%
6	100%	98,65%	97,97%	100%	96,62%	96,62%	99,32%	94,59%	98,65%
7	100%	97,97%	97,97%	100%	98,65%	97,30%	98,65%	94,59%	98,65%
8	100%	96,62%	99,32%	100%	97,97%	97,97%	100%	97,30%	99,32%
9	100%	96,62%	99,32%	100%	97,30%	98,65%	100%	99,32%	99,32%
10	100%	94,59%	97,30%	100%	97,30%	99,32%	100%	95,95%	99,32%
Média	100%	96,89%	98,45%	99,66%	97,64%	98,45%	99,66%	96,96%	99,05%
Desvio Padrão	0%	1,10%	0,91%	0,45%	0,69%	1,17%	0,45%	1,52%	0,45%
Melhor acurácia	100%	98,65%	99,32%	100%	98,65%	100%	100%	99,32%	99,32%

Tabela A.3: Acurácias e outras informações complementares obtidas nos 10 testes executados para cada combinação *ensemble* de descritores + seletor *wrapper* no *dataset* LA.

Seletor Execução	PSO			GA			bGWO		
	HF	DL	HF+DL	HF	DL	HF+DL	HF	DL	HF+DL
1	98,11%	93,56%	95,83%	98,67%	93,18%	95,64%	98,48%	93,37%	97,16%
2	98,67%	93,56%	97,73%	99,05%	93,56%	97,16%	99,24%	92,42%	96,59%
3	97,35%	93,75%	97,35%	98,48%	92,42%	96,59%	99,24%	95,45%	97,16%
4	98,30%	93,94%	96,59%	97,73%	92,80%	97,35%	98,48%	93,18%	96,97%
5	98,48%	93,94%	96,40%	98,30%	93,18%	97,35%	98,48%	93,18%	96,02%
6	98,86%	92,05%	97,16%	98,48%	92,80%	95,27%	98,86%	92,80%	95,27%
7	98,48%	93,37%	95,64%	98,67%	92,61%	97,35%	99,05%	94,13%	97,73%
8	98,48%	93,75%	96,78%	99,24%	92,99%	96,97%	98,48%	92,99%	95,08%
9	98,67%	93,56%	97,35%	98,67%	92,99%	96,40%	98,11%	94,13%	95,83%
10	97,54%	93,56%	97,73%	98,48%	93,56%	97,16%	98,86%	92,23%	96,59%
Média	98,30%	93,50%	96,86%	98,58%	93,01%	96,72%	98,73%	93,39%	96,44%
Desvio Padrão	0,47%	0,52%	0,70%	0,39%	0,35%	0,71%	0,36%	0,91%	0,82%
Melhor acurácia	98,86%	93,94%	97,73%	99,24%	93,56%	97,35%	99,24%	95,45%	97,73%

Tabela A.4: Acurácias e outras informações complementares obtidas nos 10 testes executados para cada combinação *ensemble* de descritores + seletor *wrapper* no *dataset* LG.

Seletor Execução	PSO			GA			bGWO		
	HF	DL	HF+DL	HF	DL	HF+DL	HF	DL	HF+DL
1	99,62%	98,49%	98,87%	99,25%	98,87%	98,87%	99,62%	98,49%	99,62%
2	99,25%	98,49%	98,87%	98,87%	98,87%	98,87%	98,87%	98,49%	99,62%
3	99,25%	98,11%	99,62%	99,62%	98,87%	98,11%	99,62%	98,87%	100%
4	99,62%	98,49%	98,87%	99,62%	97,74%	100%	99,25%	98,49%	99,25%
5	99,25%	98,87%	100%	99,62%	98,49%	98,87%	99,25%	98,49%	99,25%
6	99,62%	99,25%	99,62%	98,87%	98,87%	100%	99,62%	98,87%	99,62%
7	99,25%	99,25%	100%	99,25%	98,11%	99,62%	99,25%	98,87%	98,87%
8	98,87%	98,87%	98,87%	99,62%	99,62%	100%	99,25%	99,25%	99,62%
9	98,87%	99,25%	99,62%	99,25%	98,87%	99,25%	100%	99,25%	99,25%
10	100%	98,49%	99,62%	99,62%	99,25%	100%	98,87%	99,62%	99,62%
Média	99,36%	98,75%	99,40%	99,36%	98,45%	99,36%	99,36%	98,87%	99,47%
Desvio Padrão	0,34%	0,38%	0,45%	0,29%	0,51%	0,63%	0,34%	0,38%	0,30%
Melhor acurácia	100%	99,25%	100%	99,62%	99,62%	100%	100%	99,62%	100%

Tabela A.5: Acurácias e outras informações complementares obtidas nos 10 testes executados para cada combinação *ensemble* de descritores + seletor *wrapper* no *dataset* NHL.

Seletor Execução	PSO			GA			bGWO		
	HF	DL	HF+DL	HF	DL	HF+DL	HF	DL	HF+DL
1	78,61%	91,71%	91,98%	79,14%	91,44%	89,57%	79,41%	87,97%	90,11%
2	76,47%	88,24%	90,91%	76,47%	88,50%	89,57%	78,61%	92,25%	89,30%
3	78,88%	90,37%	89,30%	76,74%	90,64%	92,25%	78,61%	90,37%	91,44%
4	77,54%	89,57%	91,18%	78,34%	94,12%	91,18%	76,74%	88,77%	92,25%
5	77,01%	91,18%	89,30%	79,95%	89,84%	89,84%	77,54%	90,11%	90,11%
6	78,07%	91,44%	89,57%	77,54%	90,91%	89,57%	76,47%	91,44%	89,84%
7	79,14%	89,04%	92,25%	76,47%	90,37%	91,98%	78,61%	90,64%	90,64%
8	78,34%	90,64%	91,44%	77,81%	90,64%	90,11%	76,47%	89,57%	91,18%
9	78,34%	91,18%	89,04%	75,94%	88,77%	91,71%	80,21%	89,84%	90,64%
10	77,81%	93,05%	90,11%	77,54%	90,37%	91,44%	76,74%	90,37%	88,77%
Média	78,02%	90,64%	90,51%	77,59%	90,56%	90,72%	77,94%	90,13%	90,43%
Desvio Padrão	0,79%	1,33%	1,13%	1,21%	1,47%	1,04%	1,27%	1,16%	0,98%
Melhor acurácia	79,14%	93,05%	92,25%	79,95%	94,12%	92,25%	80,21%	92,25%	92,25%