



UNIVERSIDADE FEDERAL DO CEARÁ

CAMPUS SOBRAL

**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
COMPUTAÇÃO (PPGEEC)**

MESTRADO ACADÊMICO EM ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO

MACÁRIO MARTINS LEITÃO JÚNIOR

**ASSINATURAS ALTERNATIVAS DE TEXTURA BASEADAS EM REDES NEURAIS
RANDOMIZADAS**

SOBRAL

2019

MACÁRIO MARTINS LEITÃO JÚNIOR

ASSINATURAS ALTERNATIVAS DE TEXTURA BASEADAS EM REDES NEURAI
RANDOMIZADAS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação (PPGEEC) do *Campus* Sobral da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica e de Computação. Área de Concentração: Sistemas de Informação

Orientador: Prof. Dr. Jarbas Joaci de Mesquita Sá Junior

SOBRAL

2019

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

L549a Leitão Júnior, Macário Martins.

Assinaturas Alternativas de Textura baseadas em Redes Neurais Randomizadas / Macário Martins

Leitão Júnior. – 2019.

71 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Campus de Sobral, Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Sobral, 2019.

Orientação: Prof. Dr. Jarbas Joaci de Mesquita Sá Junior.

1. Visão Computacional. 2. Redes Neurais Randomizadas. 3. Assinatura de Textura. I. Título.

CDD 621.3

MACÁRIO MARTINS LEITÃO JÚNIOR

ASSINATURAS ALTERNATIVAS DE TEXTURA BASEADAS EM REDES NEURAI
RANDOMIZADAS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação (PPGEEC) do *Campus* Sobral da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica e de Computação. Área de Concentração: Sistemas de Informação

Aprovada em: 17 de Dezembro de 2019

BANCA EXAMINADORA

Prof. Dr. Jarbas Joaci de Mesquita Sá
Junior (Orientador)
Universidade Federal do Ceará (PPGEEC / UFC)

Prof. Dr. Iális Cavalcante de Paula Júnior
Universidade Federal do Ceará (PPGEEC / UFC)

Prof(a). Dra. Fátima Nelsizeuma Sombra de Medeiros
Universidade Federal do Ceará (PPGETI / UFC)

Dedico este trabalho aos meus pais e à minha amada Sabrina, pelo incentivo e suporte incondicionais que me forneceram durante toda essa jornada.

AGRADECIMENTOS

Aos meus pais, Macário Martins Leitão Neto e Helena Maria de Oliveira Martins, pela motivação que sempre me deram em relação aos estudos. Obrigado por todo o amor e carinho que dedicaram a mim.

À minha amada Sabrina Alves Aragão Lima, que em diversos momentos foi meu mais precioso cais. Suas palavras e reflexões foram o combustível necessário para que eu pudesse realizar várias façanhas durante o percurso do mestrado. Muito obrigado!

Aos meus irmãos, Thalys Gustavo de Oliveira Martins e Thamyres Helena de Oliveira Martins, pelo apoio e torcida.

Ao Prof. Dr. Jarbas Joaci de Mesquita Sá Junior, por aceitar ser meu orientador, por fornecer prontamente todos os insumos que foram necessários, por compartilhar seu conhecimento, por ser fonte de inspiração e, sobretudo, por ter sido tão paciente e gentil. Ao Prof. Jarbas: Gratidão!

Ao Prof. Dr. Iális Cavalcante de Paula Júnior, por ter sido tão bom professor e coordenador, por me acolher no PPGEEC, pela sua disponibilidade em ter me auxiliado sempre que necessário. Essas atitudes tornaram a minha experiência mais agradável. Obrigado.

Aos meus amigos Anderson Barbosa Rodrigues, André Alves Bezerra e Francisco Danilo da Silva Lima, por acreditarem na minha capacidade e incentivarem-me a realizar o mestrado. Agradeço-lhes também pelo apoio intensivo em diversos momentos. Obrigado.

Aos meus colegas e amigos de mestrado. Em particular, a David Borges, Danilo Alves, Euclides Barrozo, Pablo Espinoza e Raimundo Farrapo. A estes três últimos, agradeço com carinho especial por todo o suporte, palavras amigas e incentivo que puderam me dar.

Ao Centro Universitário Inta (Uninta) por conceder liberação e flexibilidade nas minhas jornadas de trabalho, a fim de que eu pudesse buscar mais qualificação.

A todos os professores e funcionários da Universidade Federal do Ceará (UFC) que contribuíram direta ou indiretamente para a viabilização dos estudos empreendidos neste trabalho.

Ao Doutorando em Engenharia Elétrica, Ednardo Moreira Rodrigues, e seu assistente, Alan Batista de Oliveira, aluno de graduação em Engenharia Elétrica, pela adequação do *template* utilizado neste trabalho para que o mesmo ficasse de acordo com as normas da biblioteca da UFC.

“Um dia, quando olhares para trás, verás que os dias mais belos foram aqueles em que lutaste.”

(Sigmund Freud)

RESUMO

Assinaturas de textura são descritores extraídos de imagens digitais que permitem uma representação genérica a respeito de toda ou apenas parte da imagem. Esses descritores são particularmente importantes pois permitem a realização de diversas tarefas em visão computacional, incluindo a classificação de texturas. O sucesso da tarefa de classificação depende intimamente da qualidade dos descritores utilizados. Essa qualidade, por sua vez, é determinada pela separabilidade que os descritores são capazes de promover às diferentes classes envolvidas. Naturalmente, as amostras de uma mesma classe devem ainda permanecer o mais próximo possível umas das outras. O desenvolvimento de assinaturas de qualidade é, portanto, um importante objeto de estudo, uma vez que a caracterização adequada de texturas possibilita classificações mais assertivas, alcançadas com menores complexidade e custo computacionais. Neste trabalho, a maneira de caracterizar texturas é abordada com enfoque nas assinaturas produzidas a partir de Redes Neurais Randomizadas (RNN), uma maneira bastante recente de descrever texturas e que apresenta resultados relevantes. A partir desse tipo de descritor, quatro novas abordagens são propostas, visando aprimorar as assinaturas baseadas em RNN e obter resultados ainda melhores. As abordagens propostas neste trabalho são aplicadas a cinco bases de imagens, extraindo-lhes novas assinaturas. Em seguida, essas assinaturas são submetidas a dois métodos de validação cruzada, a fim de estimar a acurácia que elas podem fornecer quando aplicadas à classificação de texturas, obtendo, dessa forma, uma maneira de compará-las a outros métodos presentes na literatura. Os resultados obtidos mostram que as abordagens propostas são alternativas viáveis enquanto descritores de texturas e elevam efetivamente as taxas de acerto das assinaturas baseadas em RNN, no contexto de classificação. Esses resultados mostram ainda que as assinaturas propostas são competitivas, superando os resultados de métodos tradicionais e modernos presentes na literatura.

Palavras-chave: Visão Computacional, Redes Neurais Randomizadas, Assinatura de Textura

ABSTRACT

Texture signatures are descriptors extracted from digital images. They allow a generic representation of the whole or only part of the image. These descriptors are particularly important because they allow the accomplishment of several tasks in computer vision, including texture classification. The success of the classification task depends closely on the used descriptors' quality. This quality is determined by the separability that the descriptors are able to promote to the different classes. Of course, samples of the same class should still remain as close as possible to each other. The proposition of quality signatures is therefore an important object of study, since proper characterization of textures enables more assertive classifications, achieved with lower computational complexity and cost. In this work, the characterization of textures is approached with focus on the signatures produced from Randomized Neural Networks (RNN), a very recent way to describe textures and that presents remarkable results. Based on this type of descriptor, four new approaches are proposed to improve RNN-based signatures and obtain even better results. The approaches proposed in this work are applied to five image databases, extracting new signatures. These signatures are then submitted to two cross-validation methods in order to estimate the accuracy they can provide when applied to texture classification, thus obtaining a way to compare them with other methods in the literature. The results show that the proposed approaches are feasible alternatives as texture descriptors and effectively increase the RNN-based signature success rates in the classification context. These results also show that the proposed signatures are competitive, surpassing the results of traditional and modern methods present in the literature.

Keywords: Computer Vision, Randomized Neural Network, Texture Signature

LISTA DE FIGURAS

Figura 1 – Diagrama da topologia de uma RNN e todas as entidades envolvidas no processo de treinamento.	26
Figura 2 – Diagrama com exemplo de um rótulo e seu respectivo vetor de características para uma janela 3×3 pixels.	28
Figura 3 – Diagrama com exemplos de vizinhanças de um pixel central para janelas de tamanhos 5×5 , 7×7 e 9×9 pixels pelo método proposto por (SÁ JUNIOR; BACKES, 2016).	29
Figura 4 – Diagrama com exemplos de vizinhanças de um pixel central para janelas de tamanhos 5×5 , 7×7 e 9×9 pixels para a abordagem de Média dos Rótulos.	32
Figura 5 – Diagrama com exemplos de vizinhanças de um pixel central para janelas de tamanhos 5×5 , 7×7 e 9×9 pixels para a abordagem de Vetor de Rótulos.	33
Figura 6 – Diagrama com exemplos de vizinhanças de um pixel central para janelas de tamanhos 5×5 , 7×7 e 9×9 pixels para a abordagem de Rótulos Híbridos.	35
Figura 7 – Diagrama com exemplos de vizinhanças de um pixel central para janelas de tamanhos 5×5 , 7×7 e 9×9 pixels para a abordagem de Expansão de Características.	36
Figura 8 – Imagens de texturas da base de Brodatz.	37
Figura 9 – Imagens de texturas da base Outex TC00013 Suite.	38
Figura 10 – Imagens de texturas da base VisTex.	39
Figura 11 – Imagens da base: A primeira linha (grifada em verde) mostra as três subclasses consideradas como normais, enquanto a segunda linha (grifada em vermelho) mostra as quatro subclasses consideradas anormais.	40
Figura 12 – Imagens das amostras das ligas de titânio. A imagem da esquerda representa a classe α e β , enquanto a imagem à direita representa a classe $\alpha + \beta$	43

LISTA DE TABELAS

Tabela 1	– Quantidade de amostras por classe na base de imagens da Cérvix Uterina.	40
Tabela 2	– Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K para a base de Brodatz.	48
Tabela 3	– Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K para a base Outex.	48
Tabela 4	– Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K para a base VisTex.	48
Tabela 5	– Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K para a base de Brodatz.	49
Tabela 6	– Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K para a base Outex.	49
Tabela 7	– Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K para a base VisTex.	49
Tabela 8	– Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K_2 para a base de Brodatz.	50
Tabela 9	– Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K_2 para a base Outex.	50
Tabela 10	– Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K_2 para a base VisTex.	51
Tabela 11	– Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K_2 para a base de Brodatz.	51
Tabela 12	– Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K_2 para a base Outex.	51
Tabela 13	– Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K_2 para a base VisTex.	51
Tabela 14	– Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K para a base Imagens da Cérvix Uterina.	52
Tabela 15	– Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K para a base Ligas de Titânio Ti-6Al-4V.	52
Tabela 16	– Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K para a base Imagens da Cérvix Uterina.	53

Tabela 17 – Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K para a base Ligas de Titânio Ti-6Al-4V.	53
Tabela 18 – Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K_2 para a base Imagens da Cérvix Uterina.	54
Tabela 19 – Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K_2 para a base Ligas de Titânio Ti-6Al-4V.	54
Tabela 20 – Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K_2 para a base Imagens da Cérvix Uterina.	54
Tabela 21 – Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K_2 para a base Ligas de Titânio Ti-6Al-4V.	54
Tabela 22 – Comparação das acurácias médias das assinaturas baseadas em RNN com outros métodos. Configuração de janelas K e validação LOO.	56
Tabela 23 – Comparação das acurácias médias das assinaturas baseadas em RNN com outros métodos. Configuração de janelas K e validação 10-fold.	58
Tabela 24 – Comparação das acurácias médias das assinaturas baseadas em RNN com outros métodos, nas bases de Imagens da Cérvix Uterina e Ligas de Titânio Ti-6Al-4V com validação LOO.	61

LISTA DE ABREVIATURAS E SIGLAS

CLBP	Padrão binário local completo / <i>Complete Local Binary Pattern</i>
CNTD	Descritor de Textura baseado em Redes Complexas / <i>Complex Network-based Texture Descriptor</i>
DCT	Transformada discreta do cosseno / <i>Discrete Cosine Transform</i>
ELM	Máquina de Aprendizado Extremo / <i>Extreme Learning Machine</i>
FSW	Soldagem por Fricção / <i>Friction Stir Welding</i>
GLCM	Matrizes de Coocorrência dos Níveis de Cinza / <i>Gray-Level Cooccurrence Matrices</i>
GLDM	Matriz de diferença de níveis de cinza / <i>Gray-Level Difference Matrix</i>
K-NN	K-ésimo Vizinho mais Próximo / <i>K-Nearest Neighbor</i>
LBP	Padrões Binários Locais / <i>Local Binary Patterns</i>
LBPV	Variância de padrão binário local / <i>Local Binary Pattern Variance</i>
LCG	Gerador Congruente Linear / <i>Linear Congruent Generator</i>
LDA	Análise Discriminante Linear / <i>Linear Discriminant Analysis</i>
LOO	<i>Leave-One-Out</i>
LTP	Padrão ternário local / <i>Local Ternary Pattern</i>
RNN	Rede Neural Randomizada / <i>Randomized Neural Network</i>
TWI	<i>The Welding Institute</i>

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Problemática	16
1.2	Objetivos	17
<i>1.2.1</i>	<i>Objetivo geral</i>	<i>17</i>
<i>1.2.2</i>	<i>Objetivos específicos</i>	<i>17</i>
1.3	Organização da Dissertação	18
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	Visão Computacional	19
2.2	Texturas em imagens digitais	20
2.3	Classificação de texturas	23
2.4	Redes Neurais Randomizadas	24
3	ASSINATURA BASEADA EM REDES NEURAIAS RANDOMIZADAS	28
4	MATERIAIS E MÉTODOS	31
4.1	Métodos de extração de características	31
<i>4.1.1</i>	<i>Abordagem da Média dos Rótulos</i>	<i>31</i>
<i>4.1.2</i>	<i>Abordagem do Vetor de Rótulos</i>	<i>32</i>
<i>4.1.3</i>	<i>Abordagem de Rótulos Híbridos</i>	<i>34</i>
<i>4.1.4</i>	<i>Abordagem de Expansão de Características</i>	<i>35</i>
4.2	Bases de imagens	36
<i>4.2.1</i>	<i>Álbum de Brodatz</i>	<i>36</i>
<i>4.2.2</i>	<i>Outex TC00013 Suite</i>	<i>37</i>
<i>4.2.3</i>	<i>VisTex</i>	<i>38</i>
<i>4.2.4</i>	<i>Imagens de Cérvix Uterina</i>	<i>39</i>
<i>4.2.5</i>	<i>Ligas de Titânio Ti-6Al-4V</i>	<i>41</i>
4.3	Método de Classificação	43
4.4	Estratégias de Validação	44
<i>4.4.1</i>	<i>K-fold</i>	<i>44</i>
<i>4.4.2</i>	<i>Leave-One-Out (LOO)</i>	<i>45</i>
5	EXPERIMENTOS E RESULTADOS	46
5.1	Parâmetros dos experimentos	46

5.2	Resultados em Bases de Referência	47
5.2.1	<i>Conjunto K de janelas de análise de pixels</i>	47
5.2.2	<i>Conjunto K_2 de janelas de análise de pixels</i>	50
5.3	Resultados em bases de Aplicação	52
5.3.1	<i>Conjunto K de janelas de análise de pixels</i>	52
5.3.2	<i>Conjunto K_2 de janelas de análise de pixels</i>	53
5.4	Comparação com outras abordagens e análise dos resultados	55
6	CONCLUSÕES	63
6.1	Trabalhos Publicados	64
6.2	Trabalhos Futuros	65
	REFERÊNCIAS	66

1 INTRODUÇÃO

A visão é um dos sentidos mais complexos nos seres humanos, desde a captura das imagens pelos globos oculares à tradução dos impulsos nervosos enviados através do nervo óptico ao cérebro (GONZALEZ; WOODS, 2010). Para os seres humanos, a visão é um dos principais mecanismos para o reconhecimento do meio e também para o aprendizado (BACKES *et al.*, 2013). O reconhecimento, nesse contexto, pode ser especialmente compreendido como uma generalização do aprendizado. Isso porque a visão permite que um indivíduo capture características de objetos/seres, tais como cor, aspecto de superfície (textura), forma, dimensões, opacidade, dentre outros (BACKES; SÁ JUNIOR, 2016). Essas características são suficientes para que o cérebro humano generalize e reconheça objetos/seres similares (SHI *et al.*, 2010; PETRAS *et al.*, 2019).

Os estudos em visão computacional são conduzidos de maneira a simular o funcionamento da visão humana (ARIVAZHAGAN; GANESAN, 2003). Uma vez que esse funcionamento esteja devidamente modelado e possa ser reproduzido de maneira sistemática, tarefas mais complexas poderão ser realizadas com base em informações obtidas a partir do modelo. Todas as características visuais que o olho humano é capaz de enxergar contribuem com algum grau de relevância para as tarefas de aprendizado e/ou reconhecimento. Dentre elas, destacam-se aqui as características relacionadas a cor, textura e forma. Da mesma maneira que tais atributos são importantes para o ser humano, também o são para as técnicas desenvolvidas em visão computacional e, por isso, uma série de estudos foi (e continua sendo) desenvolvida para trabalhar essencialmente com essas três propriedades (BACKES; SÁ JUNIOR, 2016).

A textura é um dos atributos mais importantes a serem coletados na análise de imagens para tarefas de visão computacional. É especialmente relevante devido à sua capacidade de fornecer descrições distintas, isto é, fornecer informações que permitem a diferenciação entre objetos, partindo somente da informação sobre o aspecto da superfície desses objetos. Essa capacidade de diferenciação contribui para a execução de tarefas que permeiam diversos níveis de complexidade em visão computacional, tais como o reconhecimento de objetos, sensoriamento remoto, recuperação de imagens com base em conteúdo, aplicações biológicas, médicas, entre outras (SÁ JUNIOR; BACKES, 2016).

Uma seleção adequada de atributos tende a garantir que as informações levantadas sejam suficientemente relevantes a ponto de permitir a correta categorização de objetos/seres. Ao processo de seleção das informações representativas acerca de um item analisado é dado o nome

de extração de características. Esse processo, por sua vez, é uma das questões mais críticas para a classificação de texturas (SENGUR *et al.*, 2007) e, por isso, é importante que seja conduzido de maneira adequada, isto é, selecionar/gerar corretamente as características que produzirão descritores com boa capacidade de representação.

Por isso, neste trabalho, serão utilizados métodos no estado da arte da extração de características de texturas em imagens digitais. Tratam-se das assinaturas desenvolvidas por Sá Junior e Backes (2016), que serão analisadas e modificadas. As modificações propõem melhorias na extração de características, visando à elevação das capacidades descritivas dessas assinaturas e, como consequência, à elevação das acurácias na classificação de texturas.

1.1 Problemática

O descritor de texturas apresentado por Sá Junior e Backes (2016) tem uma abordagem inovadora ao utilizar redes neurais no processo de classificação de texturas. Contudo, é importante que o leitor saiba, de antemão, que a rede neural não foi utilizada para classificar os dados e sim como parte do esquema gerador de assinaturas.

A função da rede neural é relacionar os valores de entrada com as saídas esperadas. Esse relacionamento representa o “mapeamento” que liga as amostras contidas no vetor de características com seus respectivos rótulos. Assim, a geração de assinaturas mais consistentes depende da qualidade dos valores de entrada. Quanto mais parecidas as entradas da mesma classe forem, melhor será o produto final gerado pela rede neural.

As texturas são analisadas em janelas de pixels de tamanhos distintos. Cada janela é passada por toda a imagem e, durante esse processo, são extraídos vetores de características e rótulos dessas janelas. Dessa maneira são construídos os conjuntos de entrada e saída para a rede neural.

Uma vez que o procedimento de extração de características e rótulos é regular e independente do tamanho da janela, o aumento dessa janela provoca uma natural perda de informação. É justamente sobre os parâmetros utilizados para selecionar o vetor de características e rótulos que melhorias podem ser aplicadas, para reduzir o descarte de informação e ampliar a correlação das características selecionadas com seus respectivos rótulos.

A hipótese levantada é de que, conforme as janelas de pixels analisadas crescem, os pixels selecionados para a formação dos vetores de características e rótulos tendem a perder a correlação entre si, uma vez que os pixels utilizados como características ficam, normalmente,

na borda da janela e o pixel selecionado para o rótulo fica no centro. O procedimento completo será detalhado no Capítulo 3.

Essa queda de correlação acontece devido à perda da transição gradual dos tons de cinza, que se manifesta naturalmente entre pixels vizinhos. Em outras palavras, pixels adjacentes tendem a ter menor variação entre suas tonalidades devido à sua proximidade. Dessa forma, pixels de uma determinada vizinhança são similares aos seus vizinhos. Ao analisar janelas de pixels de dimensões maiores, surge espaço para que existam mais pixels entre o centro e a borda, que não serão selecionados para compor as características ou rótulos, posteriormente submetidos à rede neural.

Portanto, destacam-se dois itens, considerando a análise acerca das possíveis melhorias para o procedimento de extração de características e rótulos:

- A perda de correlação entre os pixels selecionados para o vetor de características e vetor de rótulos de uma janela de pixels conforme o tamanho dessa mesma janela é incrementado;
- Otimização do aproveitamento das informações disponíveis nas janelas de pixels utilizadas por (SÁ JUNIOR; BACKES, 2016) em suas análises.

1.2 Objetivos

Os objetivos apresentados neste trabalho demonstram não somente a orientação seguida no rumo da pesquisa como também a motivação do estudo no avanço e melhoria das capacidades discriminativas das técnicas de assinaturas de texturas em imagens digitais.

1.2.1 Objetivo geral

Produzir descritores de textura para uso em tarefas de classificação de imagens.

1.2.2 Objetivos específicos

- Extrair mais informação das janelas de pixels analisadas pelas técnicas já existentes desenvolvidas por (SÁ JUNIOR; BACKES, 2016);
- Construir descritores mais discriminativos para texturas;
- Comparar o desempenho dos descritores propostos com outros descritores de textura disponíveis na literatura.

1.3 Organização da Dissertação

A Dissertação está organizada da seguinte maneira: O Capítulo 2 apresentará toda a base teórica necessária para o desenvolvimento do trabalho. Esses conceitos fundamentais serão seguidos pelo Capítulo 3, em que o método desenvolvido por Sá Junior e Backes (2016) será abordado detalhadamente, como também serão mostradas as assinaturas sobre as quais criou-se o alicerce dos métodos que serão apresentados. Após todas essas fundamentações, os materiais e métodos empregados serão apresentados no Capítulo 4, no qual também será desenvolvido o estudo das abordagens propostas neste trabalho. No Capítulo 5 serão apresentados a descrição dos experimentos e os resultados obtidos. O desfecho será dado, enfim, com as conclusões do Capítulo 6, no qual também serão apresentados o trabalho publicado e direcionamentos para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão apresentadas as bases sobre as quais a pesquisa se fundamentou. As seções seguintes estão dispostas de maneira que o leitor aprofunde-se gradualmente na delimitação do escopo deste trabalho.

2.1 Visão Computacional

Entende-se por Visão Computacional a área de estudos que busca fazer com que máquinas (computadores e outros equipamentos) trabalhem sobre a semântica de uma imagem, isto é, mais que captar a imagem e/ou permitir sua manipulação, a visão (no sentido próprio da palavra) é a busca pela compreensão através do sentido visual. Portanto, a Visão Computacional busca atribuir às máquinas a capacidade de compreender ou obter informação a partir de imagens, permitindo-lhes dar significados, tomar decisões ou realizar ações baseadas em informação visual (GONZALEZ; WOODS, 2010).

Para delimitar o conceito de imagem frequentemente empregado neste trabalho, devem ser consideradas as imagens digitais (ou digitalizadas), que são o produto final de um processo de aquisição realizado por celulares, filmadoras, digitalizadores, aparelhos de raios-X, etc. Será chamada “imagem” a representação eletrônica dessas informações visuais captadas do mundo exterior, visíveis ou não a olho nu (como filmagens em infra-vermelho, por exemplo).

Para que as máquinas possam efetivamente realizar todas as tarefas mencionadas anteriormente, da maneira mais aproximada possível do modelo em que a visão humana trabalha, muitas sub-tarefas são necessárias, tais como a percepção de profundidade, separação de áreas de interesse (segmentação), reconhecimento de objetos a partir de suas formas, cores, luminosidade, opacidade e textura (BACKES; SÁ JUNIOR, 2016). E é com base em todos esses atributos visuais que os seres humanos são capazes de “rotular” objetos, paisagens, cenas, materiais.

A rotulação visual atribuída a seres ou objetos serve para reconhecê-los e dividi-los em categorias, além de funcionar como base de conhecimento para o cérebro quando é necessário rotular um novo objeto que não tenha sido visualizado antes (PETRAS *et al.*, 2019). A partir de observações passadas é possível categorizar novas amostras, não apresentadas anteriormente, considerando as similaridades que possuem com amostras já observadas e devidamente rotuladas. A visão humana é, portanto, uma poderosa ferramenta para a coleta de características visuais utilizadas para o aprendizado e rotulação de observações (BACKES; SÁ JUNIOR, 2016).

Esse processo de rotulação pode se desenvolver com todos os tipos de atributos mencionados anteriormente. É também sobre esse processo de aquisição de características, aprendizado e classificação, que os capítulos e seções a seguir tratarão, especialmente sobre os atributos de texturas captadas visualmente.

2.2 Texturas em imagens digitais

Dentre as informações visuais captadas pelos processos de aquisição de uma imagem digital, uma das características relevantes é a textura, podendo ser encontrada em qualquer imagem e interpretada de diferentes formas. Uma textura visual, por assim dizer, pode ser entendida como uma característica que fornece a percepção da superfície dos objetos como suavidade, rugosidade e regularidade (TAMURA *et al.*, 1978; GONZALEZ; WOODS, 2010). As texturas podem ainda ser definidas como um agrupamento de similaridades em uma imagem (ROSENFELD; KAK, 1982); ou como imagens construídas a partir da repetição exata (ou com uma variação sutil) de um padrão sobre uma superfície (PRATT, 1991; BACKES *et al.*, 2009). Apesar de essas definições compreenderem uma ampla variedade de texturas, sobretudo aquelas não produzidas pela natureza (texturas artificiais), tais definições não generalizam suficientemente bem para as texturas naturais, como troncos de árvores, névoa ou fumaça, uma vez que estas duas últimas texturas, por exemplo, apresentam padrões estocásticos que resultam em uma aparência semelhante a de nuvem (KAPLAN, 1999).

Há ainda muitas outras definições que podem ser encontradas na literatura. Algumas delas podem ser lidas em uma compilação feita por Coggins (1982). O conjunto de conceitos apresentados até aqui demonstra que a “definição” de textura é incerta e formulada de maneiras distintas, adaptada de acordo com a especificidade da aplicação na qual cada autor trabalhou, de forma que não existe uma definição de comum acordo (ZUCKER; KANT, 1981; LIU *et al.*, 2019). Algumas definições são motivadas pelas experiências sensoriais e outras são estritamente motivadas pela aplicação em que serão usadas.

As diferenças de motivação durante a criação das definições de textura interferem diretamente nas abordagens desenvolvidas para a caracterização de texturas em imagens digitais. As abordagens adotadas na maioria dos métodos desenvolvidos para a análise de imagens de textura é baseada em duas estratégias, que são fundamentadas em características locais ou em análise multi-escala, ou ainda em uma combinação de ambas (SILVA; FLORINDO, 2019). Na primeira abordagem, os descritores são extraídos de partições locais, como Matrizes de

Coocorrência dos Níveis de Cinza / *Gray-Level Cooccurrence Matrices* (GLCM) (HARALICK, 1979), Padrões Binários Locais / *Local Binary Patterns* (LBP) (OJALA *et al.*, 2002b) e Caminhos Mínimos em Grafos (SÁ JUNIOR *et al.*, 2014). Na segunda abordagem, os recursos são calculados em diferentes níveis de escala e unificados posteriormente, como Pirâmide Espacial (LAZEBNIK *et al.*, 2006) e Descritores Fractais e Multifractais (XU *et al.*, 2009; BACKES *et al.*, 2009).

As pesquisas na área de texturas visuais não são limitadas pela ausência de uma definição formal e muitos avanços continuam a ser obtidos, permitindo outras formas de extrair informação e compreender imagens digitais a partir de suas texturas. O progresso desses avanços são refletidos nas aplicações em diversas tarefas de visão computacional, tais como segmentação de regiões com base na textura, classificação e síntese de texturas, utilizada para a compressão de imagens (TUCERYAN; JAIN, 1993).

Atualmente os métodos de extração de características de textura podem ser divididos em sete classes: estatísticos, estruturais, baseados em transformação, baseados em modelo, baseadas em grafos, baseados em aprendizado de máquina e baseados em entropia (HUMEAU-HEURTIER, 2019).

Nas abordagens estatísticas os descritores de textura são gerados a partir da distribuição espacial dos diferentes níveis de cinza que compõem a imagem (HUMEAU-HEURTIER, 2019). Enquadram-se aqui métodos clássicos como GLCM (HARALICK, 1979), LBP (OJALA *et al.*, 2002b) e as características de Tamura *et al.* (1978).

As abordagens estruturais recebem esse nome devido à maneira como caracterizam as texturas. Nessas abordagens assume-se que uma textura é o produto da repetição mais ou menos regular de um elemento estruturante, também chamado de primitiva textural. O objetivo dessas abordagens é, portanto, identificar as primitivas texturais e suas regras de posicionamento, que determinam como as primitivas são ajustadas espacialmente entre si (HUMEAU-HEURTIER, 2019). Nessa categoria destaca-se o uso de morfologia matemática (SERRA, 1983; HARALICK *et al.*, 1987; CHEN; DOUGHERTY, 1994).

Os descritores de textura baseados em transformação são aqueles que caracterizam uma imagem pelas propriedades que sua representação manifesta em um determinado espaço (como a frequência ou o espaço de uma escala). Esse espaço é escolhido de modo que seu sistema de coordenadas permita interpretações relacionadas com características texturais (HUMEAU-HEURTIER, 2019). Nessa categoria destacam-se os descritores de Fourier (AZENCOTT *et al.*,

1997) e descritores baseados em Wavelets (CHANG; KUO, 1993; SENGUR *et al.*, 2007).

As abordagens baseadas em modelo são assim chamadas porque sua estratégia consiste na representação da textura por meio de algum modelo matemático como fractais ou modelos estocásticos. Nessas abordagens o modelo é aplicado à imagem e a representação resultante é utilizada para a caracterização (HUMEAU-HEURTIER, 2019). Nesse grupo enquadram-se os descritores baseados em Redes Complexas (BACKES *et al.*, 2013), descritores fractais (XU *et al.*, 2009; BACKES *et al.*, 2009) e modelos gravitacionais (SÁ JUNIOR; BACKES, 2012; SÁ JUNIOR; BACKES, 2014).

Os métodos de descrição de texturas baseadas em grafos utilizam essa estrutura de dados para caracterizar as informações que qualificam a textura analisada. Essas caracterizações são feitas através de mecanismos representacionais diversos que possuem a geração de um grafo como resultado final (HUMEAU-HEURTIER, 2019). Exemplos desses processos algorítmicos são: calcular os caminhos mínimos entre grafos formados pelos pixels da imagem (SÁ JUNIOR *et al.*, 2014) e Caminhada do Turista (BACKES *et al.*, 2010).

As abordagens de descrição de texturas baseadas em entropia utilizam as medidas de entropia já utilizadas desde os anos 90 para análise de dados e sinais unidimensionais, mas até então não havia ainda uma abordagem para a aplicação dessas medidas em sinais bidimensionais, o que conseqüentemente impediu a utilização no processamento de imagens. Recentemente, novos métodos de extração de características de textura foram propostos com base nas abordagens bidimensionais de medidas de entropia unidimensionais, permitindo que a entropia de uma textura seja calculada diretamente sobre a imagem (HUMEAU-HEURTIER, 2019). Destacam-se os métodos de entropia da amostra (YEH *et al.*, 2011; SILVA *et al.*, 2016), entropia da distribuição (AZAMI *et al.*, 2017) e entropia em multiescala (SILVA *et al.*, 2016; SILVA *et al.*, 2018).

Novos métodos que usam o aprendizado de máquina como base da caracterização de texturas foram propostos recentemente. Humeau-Heurtier (2019) reuniu os métodos compreendidos nessa categoria em três subseções: os métodos de aprendizado de vocabulário, os métodos baseados em Máquina de Aprendizado Extremo / *Extreme Learning Machine* (ELM) e os métodos de aprendizado profundo (*deep learning*), sendo estes dois últimos os mais recentes. As novas propostas também impulsionaram uma retomada nos estudos de caracterização de texturas, devido às diversas aplicações nas quais podem ser empregadas. Nessa categoria destaca-se o trabalho de Sá Junior e Backes (2016) pela introdução da ELM como parte do

processo de descrição de texturas em imagens digitais. A pesquisa desta dissertação se desenvolve sobre a caracterização de texturas baseada em ELM e os descritores apresentados podem, conseqüentemente, ser categorizados também como descritores baseados em ELM.

2.3 Classificação de texturas

Os estudos para a classificação de texturas têm adquirido uma importância crescente devido à riqueza de informações que essa característica pode trazer em aplicações de visão computacional. Essas aplicações estendem-se desde a análise automatizada da qualidade de acabamentos em pinturas automotivas (FARROKHNIYA, 1990) ao suporte no diagnóstico de doenças, partindo da análise de texturas das imagens obtidas por exames, tais como mamografias (BRAZ JUNIOR *et al.*, 2009; LLADÓ *et al.*, 2009) e classificação de imagens da cérvix uterina (NANNI *et al.*, 2010; SÁ JUNIOR; BACKES, 2014; SÁ JUNIOR *et al.*, 2018a), como alguns exemplos.

A classificação de texturas consiste em decidir a qual classe ou categoria de textura uma imagem observada pertence. Para isso, é preciso ter um conhecimento *a priori* das classes a serem reconhecidas. Uma vez que esse conhecimento esteja disponível e os recursos de textura sejam extraídos, utilizam-se técnicas clássicas de reconhecimento de padrões para fazer a classificação.

O sucesso de uma classificação de texturas está relacionado a dois fatores preponderantes: o primeiro deles é, sem dúvida, a robustez do classificador empregado, isto é, o mecanismo que efetivamente faz a separação das amostras, atribuindo-as às classes que possuem aspectos que mais se identificam com aquela amostra. O segundo fator, e o mais impactante no resultado final da classificação, é a qualidade do descritor utilizado para representar (ou caracterizar) as texturas a serem classificadas. O impacto causado pela qualidade do descritor é percebido quando um mau descritor é submetido a um classificador robusto e as taxas de acerto resultantes são medíocres, ao passo que um descritor de qualidade, associado a um classificador menos robusto, é capaz de atingir resultados significativos.

Em relação à classificação de texturas é importante salientar que discutir sobre sucesso/insucesso da classificação é uma referência a quão bem as classes foram separadas por um classificador. E essa separabilidade dos dados é proveniente do quão dispersos eles se tornam quando considerados determinados descritores. A ideia subjacente é que um descritor de textura pode ser considerado bom quando, para um mesmo tipo de textura, as amostras ficam próximas

o máximo possível uma das outras, enquanto que para texturas diferentes, os grupos de amostras (classes) ficam distantes entre si o máximo possível. Em outras palavras, um bom descritor é aquele que é capaz de unir amostras de mesma classe e, ao mesmo tempo, distanciar amostras de classes diferentes. Essas “distâncias” recebem os nomes de *distância intraclasse* e *distância interclasse*, respectivamente.

Muitos trabalhos foram empreendidos para o desenvolvimento de novos descritores com a intenção de explorar diferentes maneiras de extrair características visuais. Tais trabalhos incluem abordagens como LBP (OJALA *et al.*, 2002b), Wavelets (ARIVAZHAGAN; GANESAN, 2003), Caminhada do Turista (BACKES *et al.*, 2010), dimensão fractal (SÁ JUNIOR; BACKES, 2012; BACKES *et al.*, 2012), estatísticas de segunda-ordem (HARALICK, 1979), filtros de Fourier (AZENCOTT *et al.*, 1997) e Gabor (MANJUNATH; MA, 1996), caminhos mínimos em grafos (SÁ JUNIOR *et al.*, 2014), assinaturas de textura baseadas em ELM (SÁ JUNIOR; BACKES, 2016), dentre outros.

Neste trabalho, o mecanismo de descrição de textura utilizado por Sá Junior e Backes (2016) será estudado mais detalhadamente. Dentre as propriedades importantes a serem compreendidas a respeito desse mecanismo de descrição, vale destacar o modelo inovador apresentado para a extração de características de texturas em imagens. A maneira pela qual o método de Sá Junior e Backes (2016) trabalha com as imagens de texturas torna-se atrativa por apresentar resultados significativos e figurar um avanço para o estado da arte em caracterização de texturas.

2.4 Redes Neurais Randomizadas

O tempo necessário para o treinamento de redes neurais tradicionais costuma ser longo e isso pode ser explicado por dois fatores principais. O primeiro deles é a própria velocidade do algoritmo usado para a convergência das soluções, como o algoritmo de gradiente descendente, amplamente utilizado por muitas topologias de redes neurais. E o segundo fator é que a maioria dos parâmetros são ajustados dinamicamente ao decorrer da execução desses mesmos algoritmos de treinamento (HUANG *et al.*, 2006).

Uma Rede Neural Randomizada / *Randomized Neural Network* (RNN) (SCHMIDT *et al.*, 1992; PAO; TAKEFUJI, 1992; PAO *et al.*, 1994; HUANG *et al.*, 2006) é uma rede neural artificial que, em sua versão mais simples, possui apenas uma única camada de neurônios ocultos e cujos pesos, que conectam os dados da camada de entrada aos neurônios ocultos, são

escolhidos aleatoriamente. Em uma RNN o que mais importa é a escolha dos pesos que conectam os neurônios com a camada de saída. Para isso, as respostas aos estímulos de cada neurônio oculto são conectadas à camada de saída através de pesos calculados usando uma solução de mínimos quadrados, o que torna possível o treinamento deste tipo de rede neural em apenas uma época.

Para compreender melhor o funcionamento de uma RNN, considere $X = [\vec{x}_1, \vec{x}_2, \dots, \vec{x}_N]$, uma matriz formada por N vetores de características (cada um com comprimento p), isto é, X será a base de dados contendo p características para cada uma das N amostras (instâncias), que no contexto estão relacionadas às imagens de textura.

Seja ainda $D = [\vec{d}_1, \vec{d}_2, \dots, \vec{d}_N]$, uma matriz de rótulos para cada vetor \vec{x}_i em X . Por “rótulo” entenda-se como a “classificação” da amostra \vec{x}_i . Portanto, D reúne todas as informações que categorizam as amostras de X .

Para iniciar a fase de treinamento, pesos aleatórios uniformes (ou gaussianos) são gerados e organizados em uma matriz

$$W = \begin{pmatrix} w_{10} & w_{11} & \dots & w_{1p} \\ w_{20} & w_{21} & \dots & w_{2p} \\ \vdots & \vdots & \vdots & \vdots \\ w_{q0} & w_{q1} & \dots & w_{qp} \end{pmatrix}, \quad (2.1)$$

na qual q é o número de neurônios ocultos e p , como mencionado anteriormente, é o número de características presentes nos vetores de X . Em outras palavras, cada elemento de W representa os pesos que ligam os neurônios ocultos com uma determinada característica dos vetores de X , identificados pelos índices das linhas e colunas, respectivamente. De modo análogo, cada elemento w_{qi0} é o peso do *bias*, θ_{qi} .

O *bias* é uma constante que deve ser anexada a cada vetor de características em X para conectá-la ao seu respectivo peso θ_{qi} em W . Após esse procedimento, é possível calcular a saída dos nós ocultos, através da equação

$$Z = \phi(WX), \quad (2.2)$$

em que ϕ é a função de ativação do neurônio. A matriz $Z = [\vec{z}_1, \vec{z}_2, \dots, \vec{z}_N]$, resultante dessa operação, pode ser entendida como o conjunto de respostas dos neurônios ocultos aos estímulos gerados pelo produto dos pesos e dados de entrada.


A matriz Z pode ser usada como outro conjunto de vetores de características a ser apresentado à camada de saída. Novamente, é necessário adicionar um valor constante a cada vetor \vec{z}_i para conectá-lo a cada *bias* dos neurônios de saída.

Uma vez que cada *bias* foi adicionado à matriz Z , então o relacionamento entre saídas esperadas D e respostas aos estímulos Z , geradas pelo produto dos vetores de entrada e os pesos aleatórios, é obtido como a solução de

$$D = MZ. \quad (2.3)$$

Em uma RNN, X e D são, respectivamente, a entrada e saída esperada da classificação da rede neural. Fornecendo X como entrada, uma rede neural bem treinada deve devolver uma resposta igual (ou muito próxima) a D . O treinamento, portanto, consiste em encontrar uma matriz de pesos que, de maneira eficiente, realize o relacionamento entre os dados de entrada e saída com o objetivo de minimizar o erro gerado.

Figura 1 – Diagrama da topologia de uma RNN e todas as entidades envolvidas no processo de treinamento.



Fonte: Imagem obtida do trabalho (LEITÃO JÚNIOR; SÁ JUNIOR, 2019), que foi produzido como parte da pesquisa contida nesta dissertação.

Esse erro será minimizado utilizando o método de mínimos quadrados, considerando a rede neural como um sistema linear, cuja solução pode ser obtida através da minimização da soma dos quadrados das diferenças entre as saídas esperadas (matriz D) e obtidas.

Como os valores de D e Z já são conhecidos, a Equação 2.3 pode ser reescrita sob a forma de mínimos quadrados como

$$M = DZ^T (ZZ^T)^{-1}, \quad (2.4)$$

para encontrar a matriz M , na qual cada linha representa os pesos de um determinado neurônio de saída.


Um esquema para a topologia da RNN é fornecido na Figura 1 com todos os elementos de treinamento para uma instância de X . Os quadrados de cor cinza representam os vetores de características (tanto os valores de entrada quanto as respostas aos estímulos da rede neural); os círculos são nós da camada oculta e da camada de saída; e o quadrado laranja, no final, é a representação do valor de saída esperado.

3 ASSINATURA BASEADA EM REDES NEURAIIS RANDOMIZADAS

O método apresentado por Sá Junior e Backes (2016) utiliza uma RNN para criar assinaturas de texturas em imagens digitais. A atribuição da rede neural, nesta abordagem, difere do seu uso comum, já que ela não foi usada para classificar, tampouco dividir amostras em *clusters* (clusterização). Em vez disso, a rede neural foi usada para construir um novo descritor de texturas, como parte integrante de um mecanismo de extração de características.

Para atingir esse objetivo, Sá Junior e Backes (2016) atribuíram a cada pixel da imagem o papel de “classe” e aos pixels da vizinhança foi atribuído o papel de “vetor de características”. A vizinhança representa, portanto, uma “amostra” para aquela classe.

Figura 2 – Diagrama com exemplo de um rótulo e seu respectivo vetor de características para uma janela 3×3 pixels.



Fonte: Imagem adaptada de (SÁ JUNIOR; BACKES, 2016) e que está presente no trabalho (LEITÃO JÚNIOR; SÁ JUNIOR, 2019), que foi produzido como parte da pesquisa contida nesta dissertação.

Na primeira abordagem apresentada por Sá Junior e Backes (2016), os vetores de características das imagens de textura foram extraídos a partir de diferentes tamanhos de janelas de pixels. Em seguida, os pesos da camada de neurônios de saída da RNN foram usados para compor uma assinatura de imagem para cada tamanho de janela. Por fim, a primeira abordagem é concluída com a concatenação das assinaturas geradas individualmente para cada janela.

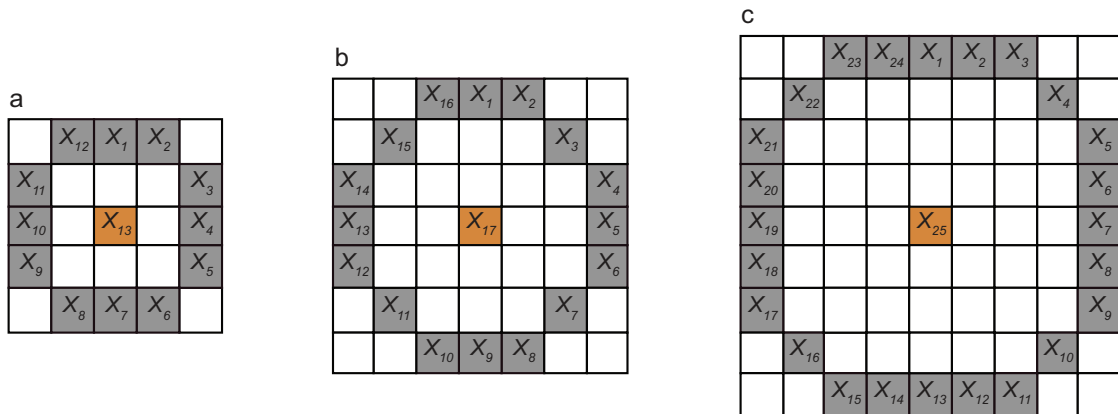
A segunda abordagem, também apresentada em (SÁ JUNIOR; BACKES, 2016), foi combinar assinaturas criadas pela primeira abordagem com números distintos de neurônios na camada oculta da RNN. Portanto, a segunda abordagem é uma concatenação de assinaturas distintas para a mesma imagem, resultando em uma nova assinatura, com maior dimensionalidade.

Para explicar como obter uma assinatura de acordo com o mecanismo desenvolvido por (SÁ JUNIOR; BACKES, 2016), considere um valor ímpar k como o tamanho da janela de

pixel analisada e divide a imagem de entrada em janelas conjuntas $k \times k$. Para cada janela, use o pixel central como um rótulo d_i e seus pixels vizinhos como o vetor de características \vec{x}_i para essa janela. A Figura 2 mostra como um rótulo e um vetor de características são extraídos de uma janela de tamanho 3×3 pixels.

A princípio, não há restrições quanto ao tamanho das janelas ou à posição dos pixels vizinhos. Em (SÁ JUNIOR; BACKES, 2016), os autores propõem janelas com tamanhos 3×3 , 5×5 e 7×7 pixels. A mesma estratégia foi seguida neste trabalho e um conjunto K de tamanhos de janelas foi definido, tal que $K = \{3, 5, 7\}$. A vizinhança pode ser determinada por uma circunferência com raio $r = k_j/2$ para cada j -ésima janela k em K , conforme mostrado na Figura 3.

Figura 3 – Diagrama com exemplos de vizinhanças de um pixel central para janelas de tamanhos 5×5 , 7×7 e 9×9 pixels pelo método proposto por (SÁ JUNIOR; BACKES, 2016).



Fonte: Figuras 3a e 3b obtidas de (SÁ JUNIOR; BACKES, 2016). Figura 3c obtida do trabalho (LEITÃO JÚNIOR; SÁ JUNIOR, 2019), que foi produzido como parte da pesquisa contida nesta dissertação.

Uma característica importante desse método é que a matriz de pesos aleatórios W deve ser a mesma para todos os descritores de textura. Então, para extrair a mesma assinatura de uma imagem em todas as fases do treinamento, W precisa ser gerada por um procedimento regular. Para isso, foi utilizado o clássico Gerador Congruente Linear / *Linear Congruent Generator* (LCG) (LEHMER, 1951; PARK; MILLER, 1988). O LCG gera valores uniformes pseudo-aleatórios, segundo a equação:

$$V_{n+1} = (aV_n + b) \pmod{c}, \quad (3.1)$$

em que V é um vetor composto por números pseudo-aleatórios, V_0 é o valor inicial (semente) e a , b , c são parâmetros para ajustar o gerador. V tem comprimento $L = Q \cdot (p + 1)$ e os valores dos parâmetros escolhidos arbitrariamente são $V_0 = L + 1$, $a = L + 2$, $b = L + 3$ e $c = L^2$, que são

valores adotados em (SÁ JUNIOR; BACKES, 2016). Em seguida, V é dividido em segmentos de Q (cada um com valores de $p + 1$) para construir a matriz W . Para concluir o procedimento, a matriz W e cada linha da matriz X são normalizadas usando o z-score, ou seja, os valores são normalizados para possuir média zero e variância unitária.

Seguindo os passos descritos anteriormente, a matriz M pode ser expressa como um vetor $\vec{f} = DZ^T (ZZ^T)^{-1}$. Com base neste vetor, os autores em (SÁ JUNIOR; BACKES, 2016) criam um vetor de características definido como

$$\vec{\Theta}(Q)_{k_1, k_2, \dots, k_n} = [\vec{f}_{k_1}, \vec{f}_{k_2}, \dots, \vec{f}_{k_n}], \quad (3.2)$$

em que k_j é o tamanho da j -ésima janela, adotado do conjunto K ; e Q é o número de neurônios ocultos. Portanto, todas as assinaturas extraídas de uma imagem com tamanhos de janela distintos e o mesmo número de neurônios são concatenadas, criando uma assinatura $\vec{\Theta}$.

O procedimento descrito acima caracteriza o primeiro tipo de assinatura proposto em (SÁ JUNIOR; BACKES, 2016), o qual foi denominado assinatura $\vec{\Theta}$. Outra assinatura, também proposta no mesmo trabalho, foi a assinatura $\vec{\Psi}$, que consiste na concatenação de assinaturas do tipo $\vec{\Theta}$. Essas assinaturas podem ser representadas sob a forma da equação:

$$\vec{\Psi}_{Q_1, Q_2, \dots, Q_m} = [\vec{\Theta}(Q_1)_{k_1, k_2, \dots, k_n}, \vec{\Theta}(Q_2)_{k_1, k_2, \dots, k_n}, \dots, \vec{\Theta}(Q_m)_{k_1, k_2, \dots, k_n}]. \quad (3.3)$$

Um exemplo da disposição dos pixels selecionados para a formação das matrizes X e D em janelas maiores é fornecida na Figura 3. Essas mesmas matrizes são submetidas à RNN como argumentos para o treinamento. Ao observar a figura atentamente, nota-se ainda que existe mais informação a ser aproveitada na janela analisada. Essa informação possui potencial para aumentar as capacidades descritivas das janelas de menor tamanho, além de melhorar a correlação entre os pixels selecionados como características e rótulos, conforme as janelas aumentam em dimensão. Qualquer melhoria aplicada ao processo de seleção das informações nas janelas de análise, como mencionado na Seção 1.1, tenderá a manifestar-se também nas assinaturas resultantes.

4 MATERIAIS E MÉTODOS

Neste capítulo serão apresentados os métodos propostos para a solução dos itens apresentados na Seção 1.1. Também serão discutidos os materiais utilizados, isto é, as bases de imagens usadas nos experimentos, assim como as maneiras pelas quais os resultados foram avaliados.

4.1 Métodos de extração de características

Recordando o modelo de extração de características apresentado por Sá Junior e Backes (2016) e considerando a hipótese levantada na Seção 1.1, conclui-se que, se houver uma maneira de extrair mais informações das partições da imagem (janelas de análise de pixels), é possível, então, otimizar a qualidade das assinaturas geradas e, por consequência, aumentar a capacidade de discriminação das assinaturas geradas pelo descritor.

Assim, serão apresentados quatro métodos para a extração de características que visam maximizar a correlação entre os pixels selecionados como vetores de características e aqueles selecionados como rótulos, aproveitando melhor a informação disponível nas janelas de pixels analisadas, antes de fornecê-las como entradas para a RNN.

As abordagens denominadas Média dos Rótulos e Vetor de Rótulos foram apresentadas no trabalho (LEITÃO JÚNIOR; SÁ JUNIOR, 2019), que foi produzido com parte do material desta pesquisa, enquanto ela se encontrava em desenvolvimento.


4.1.1 Abordagem da Média dos Rótulos

Considerando que a distância entre o centro e as bordas de uma janela de pixels analisada é um fator que implica perda de informação dessa mesma janela, propõe-se com a abordagem de média dos rótulos uma expansão dos pixels selecionados como rótulos, isto é, mais pixels serão tomados como rótulos e, dessa forma, mais informação será aproveitada da janela de pixels em análise.

Para entender como os pixels foram selecionados, considere que todos os pixels que serão usados como vetor de características (e que irão compor a matriz X) estão localizados a uma distância euclidiana r do centro, correspondente ao raio da circunferência que delimita o que será chamado doravante de “borda”. Sabendo disto, selecionam-se como “núcleo” (ou rótulos), todos os pixels que estiverem a uma distância euclidiana de, pelo menos, $r/2$, delimitando assim,

uma nova circunferência, que restringe os pixels utilizados para compor o núcleo da janela.

Figura 4 – Diagrama com exemplos de vizinhanças de um pixel central para janelas de tamanhos 5×5 , 7×7 e 9×9 pixels para a abordagem de Média dos Rótulos.



Fonte: Figuras 4a e 4b elaboradas pelo autor. Figura 4c obtida do trabalho (LEITÃO JÚNIOR; SÁ JUNIOR, 2019), que foi produzido como parte da pesquisa contida nesta dissertação.

Uma vez que os pixels do núcleo estão definidos, calcula-se a média das suas intensidades de nível de cinza, utilizando-a como rótulo das características extraídas dos pixels da borda. Essa abordagem tem como objetivo alcançar mais representatividade do núcleo em relação às bordas, isto é, incluir pixels mais próximos daqueles que serão usados como características. A média de todos os pixels envolvidos é, portanto, uma maneira de usar a contribuição que esses pixels podem fornecer para a geração de um novo rótulo.

A Figura 4 mostra como ficam os núcleos de janelas 5×5 , 7×7 e 9×9 pixels para a abordagem de Média dos Rótulos. Note que, em comparação à Figura 3, é possível evidenciar quão mais próximo o núcleo fica das características da borda.

4.1.2 Abordagem do Vetor de Rótulos

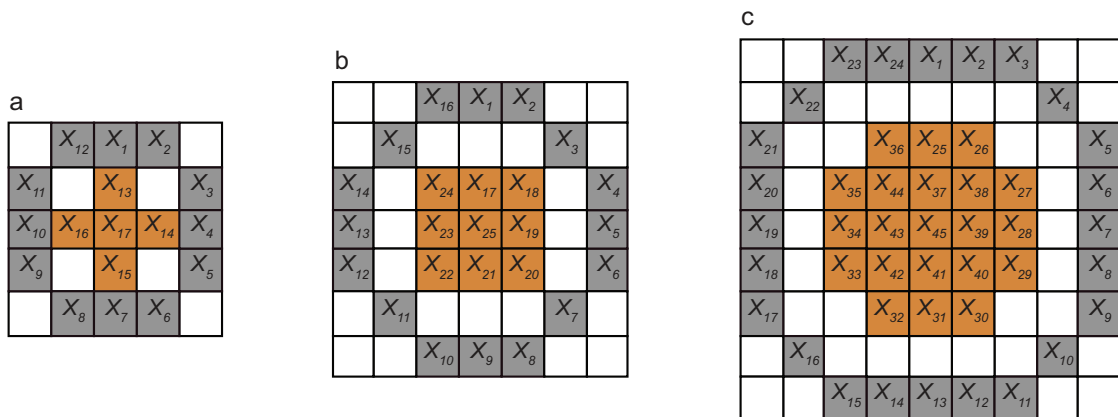
Uma outra abordagem para tornar o núcleo mais representativo em cada janela de análise de pixels é chamada de Abordagem do Vetor de Rótulos. Nesse mecanismo, assim como na abordagem da Média dos Rótulos, os pixels selecionados para compor o núcleo estão a uma distância euclidiana de pelo menos $r/2$, ou seja, os mesmos pixels da abordagem anterior são selecionados. A diferença é que esses pixels não serão combinados por meio de operações matemáticas, mas sim utilizados diretamente como rótulos para um mesmo vetor de características.

Essa abordagem se chama Vetor de Rótulos pois o vetor de características será associado a cada um dos valores que compõem o núcleo. É importante notar que a abordagem

desenvolvida por (SÁ JUNIOR; BACKES, 2016) gera, para cada rótulo, um único vetor de características final (M) na saída da RNN. Para o Vetor de Rótulos, entretanto, será gerado um vetor M para cada pixel presente no núcleo da janela analisada, formando assim uma matriz em que cada linha é composta pelas assinaturas geradas para cada pixel do núcleo e as colunas são as características que compõem o vetor de características final.

Uma vez que mais pixels são incluídos no conjunto de rótulos, d_i aumentará em dimensionalidade. Logo, d_i torna-se um vetor \vec{d}_i , para a i -ésima janela analisada, com comprimento u igual ao número de pixels dentro da distância $r/2$ do pixel central, incluindo ele próprio, portanto resultando em uma nova matriz $D_{u \times N}$. Os pixels desse novo conjunto de rótulos são coletados no sentido horário, assim como os pixels da borda (características).

Figura 5 – Diagrama com exemplos de vizinhanças de um pixel central para janelas de tamanhos 5×5 , 7×7 e 9×9 pixels para a abordagem de Vetor de Rótulos.



Fonte: Figuras 5a e 5b elaboradas pelo autor. Figura 5c obtida do trabalho (LEITÃO JÚNIOR; SÁ JUNIOR, 2019), que foi produzido como parte da pesquisa contida nesta dissertação.

Como o método Vetor de Rótulos utiliza mais pixels na composição do rótulo, a saída M torna-se bidimensional.

Diferentemente da abordagem de Média dos Rótulos e das abordagens apresentadas em (SÁ JUNIOR; BACKES, 2016), nas quais a matriz M é unidimensional, e as assinaturas são geradas a partir da concatenação de cada matriz M formada pelas janelas de dimensão k_j , na abordagem Vetor de Rótulos, o mesmo procedimento não pode ser realizado. Considerando que na abordagem Vetor de Rótulos, a matriz M , de cada janela k_j , é bidimensional e de dimensões distintas, um processamento intermediário se faz necessário para permitir a concatenação dessas matrizes e a consequente produção das assinaturas. Esse processo intermediário consiste em acoplar, umas às outras, todas as linhas de uma matriz M , obtida de uma janela k_j . Com essa estratégia é possível criar uma disposição unidimensional dos dados, representada pelo vetor \vec{g}_{k_j} .

Por fim, os vetores \vec{g}_{k_j} são usados para compor a nova assinatura $\vec{\Omega}$, expressa como

$$\vec{\Omega}(Q)_{k_1, k_2, \dots, k_n} = [\vec{g}_{k_1}, \vec{g}_{k_2}, \dots, \vec{g}_{k_n}]. \quad (4.1)$$

Para saber o número de características finais gerados pela assinatura $\vec{\Omega}$, a seguinte equação pode ser usada

$$F(\vec{\Omega}(Q)_{k_1, k_2, \dots, k_n}) = (Q + 1) \cdot \sum_{j=1}^n u_{k_j}, \quad (4.2)$$

em que $F(\cdot)$ representa o número de características para uma assinatura $\vec{\Omega}$ gerada com Q neurônios e dimensões da janela k_n ; e u_{k_j} é o número de pixels coletados como rótulo para a dimensão da j -ésima janela.

4.1.3 Abordagem de Rótulos Híbridos

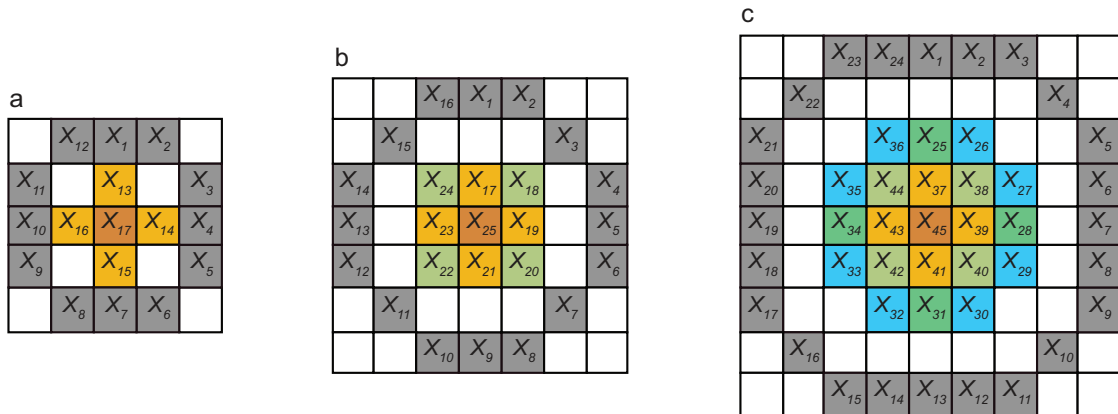
A terceira proposta visando à maior extração de informações de cada janela de pixels analisada é a abordagem de Rótulos Híbridos. Nessa abordagem, propõe-se uma junção do que foi apresentado anteriormente, isto é, o núcleo tanto será formado por um vetor de rótulos, como esses próprios rótulos serão resultados de médias de pixels do núcleo.

Serão selecionados os mesmos pixels que compõem os núcleos das abordagens anteriores. Aqui, esses pixels serão ainda divididos em grupos de acordo com a distância euclidiana a qual se encontram do pixel central. A Figura 6 mostra exemplos desse agrupamento para janelas maiores que 3×3 . Para tornar evidentes os agrupamentos, os pixels do núcleo foram coloridos de acordo com o grupo ao qual pertencem, isto é, de acordo com a distância a qual se encontram do centro de cada janela. Note ainda que o pixel central de cada janela também é utilizado como um grupo.

O que caracteriza a abordagem híbrida é que os pixels de um mesmo grupo serão sintetizados no valor médio do grupo em que se encontram. A média de cada grupo é então utilizada para compor um vetor que, assim como na abordagem de Vetor de Rótulos, produzirá uma saída M bidimensional ao ser repassado para a RNN. Todavia, é importante observar que ao realizar a operação média com cada grupo, o vetor de rótulos gerado terá uma dimensionalidade menor e, por consequência, produzirá uma matriz M com menos linhas a serem concatenadas, conduzindo a uma assinatura mais compacta.

A abordagem de Rótulos Híbridos pode ainda ser entendida como uma estratégia de redução de dimensionalidade para a abordagem de Vetor de Rótulos. Isto porque o cálculo da

Figura 6 – Diagrama com exemplos de vizinhanças de um pixel central para janelas de tamanhos 5×5 , 7×7 e 9×9 pixels para a abordagem de Rótulos Híbridos.



Fonte: Elaborado pelo autor.

média dos pixels, dispostos a uma mesma distância do centro, sintetiza a informação que tais pixels fornecem.

Outras estratégias de redução de dimensionalidade foram experimentadas para a assinatura de Vetor de Rótulos. Contudo, o procedimento adotado na assinatura de Rótulos Híbridos não implica o descarte de nenhuma informação, seja por meio de um limiar manual ou automaticamente definido, diferentemente dos métodos de redução de dimensionalidade tradicionais.

4.1.4 Abordagem de Expansão de Características

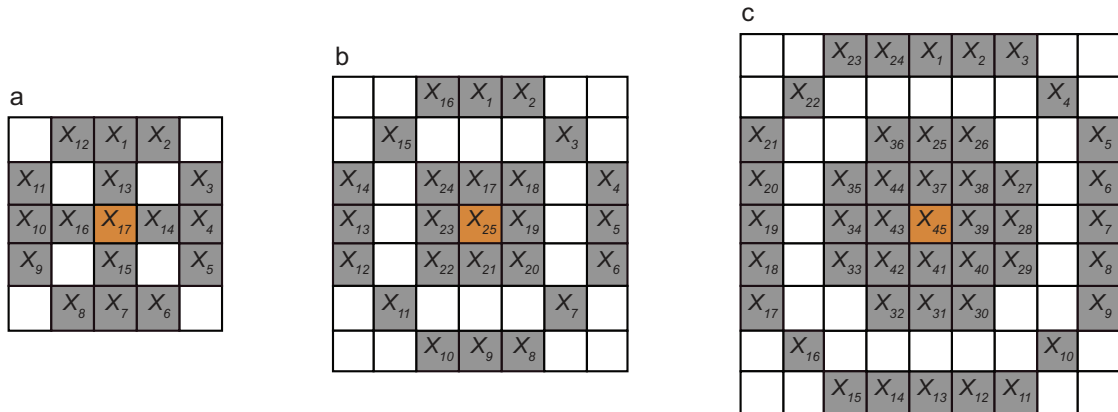
Chama-se Expansão de Características a abordagem que trabalha com a utilização de mais pixels como características em cada janela analisada. Essa estratégia possui um foco diferente dos métodos anteriores, nos quais se buscou maior representatividade do núcleo em relação às bordas das janelas de análise.

Neste método o objetivo é usar uma estratégia que selecione mais pixels à volta do centro e também próximos da borda. A esses pixels será atribuído o papel de característica, assim como nos que se encontram à borda da janela. A ideia subjacente dessa abordagem é aumentar a correlação do rótulo em relação às características, não pela ampliação do núcleo, mas sim pela aproximação das características em relação ao núcleo.

A seleção dos pixels à volta do centro ocorre como nos métodos anteriores, utilizando-se a distância euclidiana de até $r/2$, calculada a partir das coordenadas de cada pixel em relação ao centro da janela analisada.

Todos os pixels que atenderem ao critério da distância em relação ao centro, exceto

Figura 7 – Diagrama com exemplos de vizinhanças de um pixel central para janelas de tamanhos 5×5 , 7×7 e 9×9 pixels para a abordagem de Expansão de Características.



Fonte: Elaborado pelo autor.

o próprio pixel central, serão utilizados na construção do vetor de características da janela, sendo incluídos na matriz X . A construção desse vetor de características é feita pela seleção das intensidades de cinza desses pixels, em sentido-horário, partindo das bordas para o centro.

Para ilustrar esse mecanismo, a Figura 7 mostra exemplos de como são selecionados os pixels na abordagem de Características Expandidas. Note que, em todas as janelas, a vizinhança direta do pixel central está incluída como característica e que, mesmo em janelas de dimensão 9×9 , os pixels da borda estão ainda bem próximos dos pixels selecionados à volta do centro.


4.2 Bases de imagens

As bases de imagens usadas foram escolhidas por se encontrarem difundidas na literatura e apresentarem familiaridade para muitos pesquisadores da área de análise de texturas. Assim, esses conjuntos de imagens permitem uma ampla margem para a comparação dos resultados obtidos por outros autores com os resultados colhidos nos experimentos discutidos neste trabalho. As próximas subseções descrevem com mais detalhes as características das bases de imagens utilizadas, bem como as etapas que precedem os experimentos.

4.2.1 Álbum de Brodatz

A base de Brodatz (BRODATZ, 1966) é um conhecido álbum fotográfico voltado, especificamente, para texturas naturais e artificiais, publicado em 1966. Algumas das classes contidas na base são exibidas na Figura 8.

Figura 8 – Imagens de texturas da base de Brodatz.



Fonte: Brodatz (1966).

Cada uma das 111 imagens dessa base foi dividida em 16 partes, totalizando 1776 amostras. O mesmo procedimento foi adotado por Backes *et al.* (2013). As amostras são imagens quadradas de 128×128 com até 256 tons de cinza.


4.2.2 *Outex TC00013 Suite*

A base de imagens Outex é, na verdade, um *framework* completo para diversas tarefas relacionadas a texturas em imagens digitais, desenvolvido por Ojala *et al.* (2002a). A base contém um conjunto de texturas de superfícies, tanto naturais quanto artificiais. Essas texturas possuem ainda variações bem especificadas em termos de iluminação e rotação. Isso permite que uma diversidade de problemas de classificação de textura seja analisada usando o banco de dados de imagens (OJALA *et al.*, 2002a).

Como o *framework* tem como objetivo atender um elevado número de tarefas possíveis em análise de texturas, ele se divide em grupos que são identificados por duas letras. Os grupos de imagens recomendados para classificação de texturas possuem, portanto, as letras TC (*Texture Classification*) como identificadores.

Neste trabalho será utilizada a base TC00013, que possui 68 imagens coloridas de texturas (classes) naturais e artificiais, em que cada imagem possui 746×538 pixels. Assim como no trabalho de Backes *et al.* (2013), de cada uma das imagens originais foram extraídas 20 sub-imagens de 128×128 pixels, sem sobreposições e convertidas para escala de cinza, resultando assim em uma base de imagens com 1360 amostras.

Figura 9 – Imagens de texturas da base Outex TC00013 Suite.



Fonte: Ojala *et al.* (2002a).

A Figura 9 exibe exemplos das imagens já recortadas de suas respectivas imagens originais (classes), antes do pré-processamento para conversão em escala de cinza.

4.2.3 *VisTex*

A base de imagens *VisTex* (*Vision Texture*) foi desenvolvida e mantida pelo grupo de Visão e Modelagem do laboratório de Mídia do MIT (Massachusetts Institute of Technology).

Essa base foi criada com a intenção de fornecer um conjunto abrangente de texturas com alta qualidade para aplicações de visão computacional. Em particular, o conjunto foi feito como uma alternativa à biblioteca de texturas Brodatz (PICARD *et al.*, 2009).

As imagens na base *VisTex*, diferentemente de outras coleções de texturas, apresentam ainda mais variações em relação à perspectiva, pois não foram capturadas em ambientes controlados, utilizando plano frontal nem condições de iluminação de estúdio. O objetivo da base *VisTex* é fornecer imagens de textura que representem as condições de captação das imagens de texturas do mundo real (PICARD *et al.*, 2009).

Da base *VisTex* foram consideradas 54 imagens (classes) de dimensões 512×512 pixels. Nessa base de imagens, o mesmo procedimento realizado por Backes *et al.* (2013) também foi adotado. Dessa maneira, de cada imagem de *VisTex*, 16 sub-imagens (amostras) sem sobreposição e com dimensões 128×128 pixels foram extraídas, totalizando 864 amostras para os experimentos.

Assim como realizado na base Outex, as imagens *VisTex* foram convertidas para

Figura 10 – Imagens de texturas da base VisTex.



Fonte: Picard *et al.* (2009).

escala de cinza. A Figura 10 mostra algumas das sub-imagens geradas a partir das amostras de VisTex antes da conversão para escala de cinza.

4.2.4 *Imagens de Cérvix Uterina*

O carcinoma cervical é a neoplasia maligna mais comum do sistema genital feminino. O câncer do colo do útero é, mundialmente, o quarto câncer mais comum em mulheres (VAHEDPOOR *et al.*, 2019). No entanto, a carcinogênese é um processo que leva muito tempo para se desenvolver, iniciando a partir do epitélio normal, tornando-o displásico, evoluindo para carcinoma *in situ* e depois para câncer (JANTZEN *et al.*, 2005; BORA *et al.*, 2017).

O longo intervalo de tempo entre as etapas da carcinogênese permite a possibilidade de um diagnóstico precoce e, conseqüentemente, o início de um tratamento que pode alcançar a cura completa. O exame de Papanicolau é uma boa ferramenta para a triagem inicial do câncer do colo do útero, mas a análise manual das imagens do exame de Papanicolau é demorada, requer a análise de especialistas experientes, é trabalhosa e propensa ao erro humano (BORA *et al.*, 2017; WILLIAM *et al.*, 2019).

A base de dados da Cérvix Uterina, desenvolvida por Jantzen *et al.* (2005), é uma das duas que serão utilizadas neste trabalho para verificação prática das capacidades discriminativas dos métodos apresentados anteriormente.

Nesta base existem 917 imagens de células obtidas a partir de exames de Papanicolau, divididas em 7 classes. Essas classes categorizam as amostras em diferentes estágios de saúde

Tabela 1 – Quantidade de amostras por classe na base de imagens da Cérnix Uterina.


Classe	Categoria	Tipo de célula	Quantidade
1	Normal	Epitélio escamoso superficial	74
2	Normal	Epitélio escamoso intermediário	70
3	Normal	Epitélio colunar	98
4	Anormal	Displasia escamosa não queratinizante - Leve	182
5	Anormal	Displasia escamosa não queratinizante - Moderada	146
6	Anormal	Displasia escamosa não queratinizante - Grave	197
7	Anormal	Carcinoma espinocelular intermediário <i>in situ</i>	150

Fonte: Adaptado de Jantzen *et al.* (2005).

celular, partindo de células completamente saudáveis até células diagnosticadas como carcinomas. As diferentes classes usadas na construção dessa base são mostradas na Tabela 1.

A Figura 11 traz exemplos de imagens para cada uma das classes da base: (a) Epitélio escamoso superficial; (b) Epitélio escamoso intermediário; (c) Epitélio colunar; (d) Displasia escamosa não queratinizante - Leve; (e) Displasia escamosa não queratinizante - Moderada; (f) Displasia escamosa não queratinizante - Grave; e (g) Carcinoma espinocelular intermediário *in situ* (JANTZEN *et al.*, 2005).

Figura 11 – Imagens da base: A primeira linha (grifada em verde) mostra as três subclasses consideradas como normais, enquanto a segunda linha (grifada em vermelho) mostra as quatro subclasses consideradas anormais.



Fonte: Jantzen *et al.* (2005).

As células displásicas podem ser divididas em displásicas leves, moderadas e graves, como mostrado na Tabela 1. A classificação dessas células é determinada pela probabilidade de

elas se transformarem posteriormente em células cancerígenas malignas.

Uma grande quantidade de células avaliadas com displasia leve desaparecerá sem se tornar maligna. Por outro lado, células avaliadas com displasia grave possuem maior probabilidade de transformarem-se em células malignas. Em situações patológicas, o núcleo pode apresentar aumento desproporcional, irregularidade na forma e no contorno, hipercromasia ou condensação irregular da cromatina. A identificação e quantificação dessas características do núcleo contribuem para a diferenciação entre células normais e anormais nas imagens do exame de Papanicolau (PLISSITI *et al.*, 2011).

A base de imagens da Cérvix Uterina pode ser dividida ainda em duas classes: Células normais e anormais. É justamente nessa categorização que este trabalho está orientado, tendo em vista que resolver o problema da classificação em 7 classes é ainda bastante desafiador para quaisquer métodos de análise de texturas (JANTZEN *et al.*, 2005; SÁ JUNIOR *et al.*, 2018a).

Reorganizando a base de imagens, com base no problema de classes binário, a classe “Células normais” contabiliza 242 imagens e a classe “Células anormais” totaliza as demais 675 imagens. É importante notar ainda que essa base de imagens traz outros atributos desafiadores e que merecem destaque, como: classes desbalanceadas em relação à quantidade de amostras disponíveis e imagens de mesma classe com dimensões variadas.

Antes de fornecer as imagens para a extração de características dos métodos apresentados anteriormente, todas as imagens foram convertidas para escala de cinza. Em relação às variadas dimensões para cada imagem, entretanto, nenhuma padronização foi feita e essas imagens foram fornecidas aos algoritmos de extração de características do modo como se encontravam.

4.2.5 Ligas de Titânio Ti-6Al-4V

A segunda base usada para verificação prática das capacidades discriminativas dos métodos apresentados é a base de imagens de ligas de Titânio Ti-6Al-4V. Essas ligas compõem um material importante para a fabricação de peças de alta durabilidade e desempenho mecânico (BRUSCHI *et al.*, 2004) como, por exemplo, na produção de motores e estruturas de aeronaves, naves espaciais, produção química e petroquímica, geração de energia, componentes de navios da marinha, componentes automotivos, implantes médicos e dispositivos cirúrgicos (DUCATO *et al.*, 2013).

As ligas do tipo Ti-6Al-4V são constituídas de microestruturas que podem ser divididas em três classes (também chamadas de fases): α , β e $\alpha + \beta$. As microestruturas α são responsáveis pela força da liga, resistência à oxidação em altas temperaturas e tornam a soldagem da liga mais fácil. Porém, não reagem bem ao tratamento térmico e são menos resistentes quando em temperatura ambiente. As ligas $\alpha + \beta$ apresentam maior resistência e melhor reação ao tratamento térmico, mas são menos maleáveis que as ligas α . As ligas β , por fim, são responsáveis pela maleabilidade e pela resistência do material enquanto em temperatura ambiente. Por outro lado, possuem a menor resistência às altas temperaturas (MAJUMDAR; MANNA, 2015).

A fase α é estável em todas as temperaturas até aproximadamente 1153 K, a partir da qual se transforma na fase β . Essa temperatura é conhecida como *temperatura de transição β* . A fase β é estável de 1153 K ao ponto de fusão (MAJUMDAR; MANNA, 2015). As ligas formadas entre o titânio e outros elementos têm como objetivo alterar a temperatura de transição β . Esses elementos são chamados estabilizantes. Estabilizantes α aumentam a temperatura de transição β , enquanto estabilizantes β diminuem a temperatura de transição β . Na composição das ligas do tipo Ti-6Al-4V há 6% de alumínio (Al) e 4% de Vanádio (V), que são estabilizantes α e β , respectivamente (DUCATO *et al.*, 2013; MAJUMDAR; MANNA, 2015).


Embora a maioria das ligas comuns de titânio possa ser submetida à soldagem comum, podem ocorrer problemas com distorção da peça e baixa qualidade da solda. Dessa maneira, a técnica de Soldagem por Fricção / *Friction Stir Welding* (FSW), inventada no *The Welding Institute* (TWI) (THOMAS *et al.*, 1991), fornece a possibilidade de produção de soldas em ligas de titânio com alta qualidade e baixa distorção (DUCATO *et al.*, 2013).

Após a FSW, as microestruturas das ligas de titânio se reorganizam e seus agrupamentos podem ser categorizados em duas classes. A primeira classe, chamada aqui “ α e β ”, corresponde às áreas em que as microestruturas dos tipos “ α ” e “ β ” estão dispostas e cristalizadas em grãos finos. A segunda classe, “ $\alpha + \beta$ ”, é caracterizada por agrupamentos de microestruturas α e β semelhantes a cristais em seções com aparência laminada, ou ainda, semelhantes às tramas de um cesto (XU *et al.*, 2019). A formação $\alpha + \beta$ costuma apresentar-se principalmente nas zonas de solda em virtude da deformação plástica causada pelo processo de soldagem (DUCATO *et al.*, 2013). A Figura 12 mostra exemplos de ligas de titânio observadas ao microscópio, evidenciando as microestruturas α (claras) e β (escuras).

Um sistema de visão computacional capaz de classificar corretamente essas duas

classes de ligas de titânio é relevante, pois ambas as categorias possuem propriedades físicas diferentes, influenciando diretamente na qualidade dos materiais produzidos e/ou aplicações das ligas do tipo Ti-6Al-4V.

Figura 12 – Imagens das amostras das ligas de titânio. A imagem da esquerda representa a classe α e β , enquanto a imagem à direita representa a classe $\alpha + \beta$.



Fonte: Ducato *et al.* (2013).

A base de imagens Ligas de Titânio Ti-6Al-4V usada neste trabalho foi a mesma utilizada no trabalho de Sá Junior *et al.* (2018b), que foi construída a partir das imagens fornecidas pelos autores Ducato *et al.* (2013). A criação dessa base consistiu em dividir 30 imagens de dimensões de 1079×816 pixels em sub-imagens de 80×80 pixels, sem sobreposições, desprezando os pixels restantes. As 30 imagens originais são igualmente distribuídas em duas classes: “ α e β ” e “ $\alpha + \beta$ ”. Adicionalmente, para os experimentos, todas as sub-imagens geradas foram convertidas para escala de cinza antes da geração das assinaturas, para cada um dos descritores de textura apresentados anteriormente.

4.3 Método de Classificação

Para realizar a classificação das assinaturas geradas pelos métodos apresentados nas seções anteriores, utilizou-se o classificador de Análise Discriminante Linear / *Linear Discriminant Analysis* (LDA) (FISHER, 1936). Trata-se de um classificador estatístico que estima subespaços lineares nos quais as amostras de uma mesma classe podem agrupar-se da maneira mais próxima possível, enquanto os próprios subespaços amostrais se dispõem da maneira mais afastada possível uns dos outros (FUKUNAGA, 1990; EVERITT *et al.*, 2001).

O LDA foi escolhido como classificador para os experimentos, principalmente pela sua característica de ser um classificador “simples”, isto é, o produto de boas classificações

com LDA se deve, em grande parte, à qualidade dos vetores de características fornecidos como entrada.

Compete aos descritores a robustez de fornecer assinaturas suficientemente discriminantes para a obtenção de bons resultados com este tipo de classificador. Como neste trabalho são propostos novos descritores de textura, será necessário validar a qualidade das assinaturas geradas por eles e isso poderia não ser bem aferido se, de maneira diferente, fosse escolhido um classificador mais robusto.

A função discriminante que rege o funcionamento do LDA é uma generalização da função discriminante linear de Fisher (1936) e pode ser escrita como:

$$P(c_i|\vec{x}) = -\frac{1}{2}(\vec{x} - \vec{\mu}_i)^T \Sigma^{-1} (\vec{x} - \vec{\mu}_i) + \ln P(c_i), \quad (4.3)$$

em que $P(c_i|\vec{x})$ representa a probabilidade de um vetor \vec{x} pertencer à classe c_i ; $\vec{\mu}_i$ é o valor da média das amostras da classe c_i ; Σ é a matriz de covariância; e $P(c_i)$ é o valor da probabilidade da classe c_i .

Por meio da função discriminante acima, é possível realizar a classificação de uma amostra pela posição que ela ocupa em um dos subespaços delimitados pelas próprias características das amostras de cada classe.

4.4 Estratégias de Validação

Estratégias de validação são mecanismos de divisão da base de dados em conjuntos de treinamento e teste, para aferir o desempenho de um classificador. A seguir, serão apresentadas duas estratégias de validação empregadas nos experimentos deste trabalho.

4.4.1 K-fold

A estratégia K-fold consiste em dividir todas as amostras da base de dados em K subconjuntos disjuntos com a mesma (ou aproximadamente a mesma) quantidade de elementos em cada subconjunto. Em seguida, os subconjuntos são submetidos, um a um, ao classificador como subconjuntos de testes, enquanto os demais $K - 1$ subconjuntos são fornecidos como base de dados para treinamento. Esse processo é repetido K vezes, de modo que todos os subconjuntos tenham sido usados, pelo menos uma vez, como subconjunto de teste (HAYKIN, 2009).

Para os experimentos realizados neste trabalho, foi adotado $K = 10$, caracterizando assim a estratégia como 10-fold. A acurácia média (taxa de acerto) dos 10 ciclos de treinamen-

to/teste é a medida de desempenho do classificador.

4.4.2 *Leave-One-Out (LOO)*

A estratégia de validação *Leave-One-Out* (LOO) funciona de forma análoga ao K-fold. No caso do LOO, o valor de K é igual a quantidade de elementos presentes na base, isto é, $K = N$. Isto implica que os subconjuntos de teste correspondem às próprias amostras em si e, quando submetidas ao classificador, apenas uma amostra será usada como teste enquanto todas as outras serão usadas como base de dados para treinamento (HAYKIN, 2009).

Assim como na estratégia K-fold, após todas as amostras serem submetidas ao classificador, a acurácia média (taxa de acerto) dos N ciclos treinamento/teste é a medida de desempenho do classificador.

5 EXPERIMENTOS E RESULTADOS

Os experimentos foram conduzidos em cinco bases de imagens, como apresentado na Seção 4.2. Essas bases foram divididas em dois grupos: Bases de Referência e Bases de Aplicação. O primeiro grupo, composto por três bases, foi usado para a validação das melhorias propostas com métodos alternativos para a extração de assinaturas baseadas em RNN. As bases escolhidas como referência foram: Brodatz, Outex e VisTex. As outras duas bases de imagens (Imagens da Cérnix Uterina e Ligas de Titânio Ti-6Al-4V) foram extraídas de problemas reais e aplicações distintas e, por isso, foram enquadradas no grupo de Bases de Aplicação. O objetivo desse grupo é demonstrar a contribuição que as novas assinaturas podem oferecer, tanto para o estado da arte, quanto para a aplicação real do produto desta pesquisa.

Os resultados obtidos pelas assinaturas baseadas em RNN dividem-se em dois aspectos distintos. O primeiro deles é a verificação das capacidades discriminativas das abordagens propostas. O segundo aspecto é a eficiência dessas abordagens em bases de imagens coletadas a partir de problemas reais, auxiliados por visão computacional.

5.1 Parâmetros dos experimentos

Os parâmetros utilizados para gerar as assinaturas baseadas em RNN foram os mesmos usados por Sá Junior e Backes (2016): janelas de análise de pixels nas dimensões $K = \{3, 5, 7\}$ e o conjunto de neurônios $Q = \{9, 19, 29, 39, 49, 59\}$. Os parâmetros usados no LCG também foram os mesmos, isto é, para a Equação 3.1 foram adotados os valores $V_0 = L + 1$, $a = L + 2$, $b = L + 3$ e $c = L^2$, em que $L = Q \cdot (p + 1)$.

Será usado também um novo conjunto de janelas $K_2 = \{5, 7, 9\}$, para verificar o comportamento de todas as assinaturas baseadas em RNN com o aumento das dimensões das janelas de análise nas bases de Brodatz, Outex e VisTex. Essa parte dos experimentos tem como objetivo comparar os resultados das abordagens propostas com os resultados do método do qual elas partem, usando o primeiro conjunto de janelas K , e a robustez das abordagens apresentadas em relação ao distanciamento dos pixels que compõem o núcleo e a borda das janelas analisadas, usando o segundo conjunto de janelas K_2 .

Para as bases de Imagens da Cérnix Uterina e Ligas de Titânio Ti-6Al-4V, serão usados os mesmos parâmetros mencionados acima, para avaliação do desempenho dos métodos e posterior comparação dos resultados obtidos com os de outros métodos disponíveis na literatura.

Nas comparações com outras abordagens, porém, não serão consideradas todas as quantidades de neurônios presentes em Q . O valor de Q selecionado será o que possuir o melhor desempenho nas bases de imagens usadas como referência, portanto, será indicada uma quantidade de Q que possuir melhor desempenho geral para classificação de texturas.

Como mostrado nas Seções 4.3 e 4.4, os experimentos foram realizados utilizando LDA como classificador e métodos de validações cruzadas com LOO e 10-fold. Os resultados foram organizados segundo os parâmetros utilizados na criação das assinaturas. Dessa maneira, dividem-se em relação aos tipos de bases de imagens e conjuntos de janelas de análise de pixel.

5.2 Resultados em Bases de Referência

As bases de imagens de Brodatz, Outex e VisTex estão agrupadas por serem as bases utilizadas como referência, isto é, os resultados coletados a partir da aplicação das técnicas de extração de características, apresentadas na Seção 4.1, serão comparados com a abordagem adotada por Sá Junior e Backes (2016), no desenvolvimento do seu descritor de texturas, como forma de aferir o desempenho. Esse modelo de comparação foi escolhido tendo em vista evidenciar se as abordagens propostas atingem, ou não, resultados superiores para a análise de texturas.

Para efeitos de referência às abordagens desenvolvidas por Sá Junior e Backes (2016), serão adotadas as mesmas simbologias que os autores, chamando a assinatura formada pelas características extraídas da imagem diretamente com a RNN de $\vec{\Theta}$ e a segunda abordagem apresentada por Sá Junior e Backes (2016), que é a concatenação das assinaturas $\vec{\Theta}$ geradas com diferentes quantidades de neurônios, de $\vec{\Psi}$.

5.2.1 Conjunto K de janelas de análise de pixels

Os primeiros resultados apresentados são referentes à utilização do conjunto de janelas $K = \{3, 5, 7\}$ para a construção das assinaturas. As Tabelas 2, 3 e 4 apresentam os resultados das assinaturas propostas, quando submetidas à classificação com LDA e validação LOO. Os valores marcados em negrito representam as maiores taxas de acerto alcançadas por cada tipo de assinatura, com a quantidade correspondente de neurônios ocultos empregados na rede neural.

É importante observar que as assinaturas dos tipos Expansão de Características

Tabela 2 – Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K para a base de Brodatz.

Q	$\bar{\Theta}$	Taxas de Acerto por Assinatura (%)			
		Média dos Rótulos ¹	Vetor de Rótulos ¹	Expansão de Características	Rótulos Híbridos
09	91,32	91,39	94,93	90,43	92,45
19	93,58	93,64	95,38	93,41	94,09
29	94,08	94,48	95,61	94,43	94,93
39	94,14	94,37	95,21	95,05	94,88
49	95,10	95,44	96,17	95,38	95,27
59	94,65	94,99	95,16	95,66	95,38

Tabela 3 – Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K para a base Outex.

Q	$\bar{\Theta}$	Taxas de Acerto por Assinatura (%)			
		Média dos Rótulos ¹	Vetor de Rótulos ¹	Expansão de Características	Rótulos Híbridos
09	87,42	88,68	90,96	88,68	89,26
19	88,52	89,85	90,96	89,93	91,32
29	89,26	90,66	89,56	89,63	90,15
39	88,82	90,88	90,37	90,74	90,37
49	88,75	90,15	88,82	90,37	89,78
59	87,35	90,59	89,63	90,88	91,18

Tabela 4 – Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K para a base VisTex.

Q	$\bar{\Theta}$	Taxas de Acerto por Assinatura (%)			
		Média dos Rótulos ¹	Vetor de Rótulos ¹	Expansão de Características	Rótulos Híbridos
09	94,21	95,72	98,15	96,18	96,64
19	97,22	97,34	99,07	97,11	98,50
29	97,80	98,50	98,73	98,15	98,84
39	98,03	97,92	98,50	98,15	98,26
49	98,03	98,50	90,51	98,50	98,61
59	98,26	98,73	-	98,73	98,96

e Rótulos Híbridos podem apresentar acurácias ainda melhores aumentando a quantidade de neurônios da camada oculta na RNN.

A Tabela 4 possui um item ausente na coluna de Vetor de Rótulos, com 59 neurônios. O hífen (-), adotado nesse caso, representa a impossibilidade do LDA de classificar devido ao número de características presentes na assinatura. Essa notação se repetirá sempre que o classificador não for capaz de realizar sua tarefa.

As Tabelas 5, 6 e 7 apresentam as acurácias médias das assinaturas quando submetidas à validação com 10-fold. Os valores destacados em negrito representam as maiores acurácias obtidas por cada assinatura.

¹ Esses resultados encontram-se publicados em (LEITÃO JÚNIOR; SÁ JUNIOR, 2019), trabalho que foi produzido como parte da pesquisa contida nesta dissertação.

Tabela 5 – Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K para a base de Brodatz.

Q	Taxas de Acerto por Assinatura (%)			
	Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	91,19	95,50	89,12	92,50
19	93,42	96,24	94,17	94,74
29	93,99	95,30	94,74	94,55
39	94,93	95,87	95,87	95,68
49	96,43	95,31	96,62	95,31
59	96,05	95,30	96,62	95,86

Tabela 6 – Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K para a base Outex.

Q	Taxas de Acerto por Assinatura (%)			
	Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	88,24	92,40	87,01	89,22
19	89,46	91,18	91,18	93,38
29	89,71	87,99	87,50	88,24
39	89,95	88,48	93,14	89,46
49	87,01	87,25	87,75	87,75
59	89,46	88,48	91,67	88,97

Tabela 7 – Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K para a base VisTex.

Q	Taxas de Acerto por Assinatura (%)			
	Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	94,19	96,90	93,80	94,96
19	97,31	98,85	98,08	98,85
29	98,85	99,61	98,08	99,23
39	96,91	96,13	97,29	98,07
49	98,08	33,44	99,23	98,46
59	97,67	-	97,67	98,06

A fim de selecionar a melhor configuração para a criação das assinaturas, segundo seus tipos, é possível calcular a média das acurácias, obtidas por uma mesma assinatura, nas três bases de imagens de referência. Nessas médias foram consideradas todas as acurácias registradas, isto é, tanto as obtidas por validação LOO como por 10-fold.

A definição dessas configurações é importante para que os resultados, atingidos por cada assinatura, sejam comparados com outros descritores de textura disponíveis na literatura, sem que necessariamente todas as configurações sejam testadas uma outra vez.

Para a assinatura $\vec{\Theta}$, a melhor configuração foi definida em (SÁ JUNIOR; BACKES, 2016) como $Q = 39$, para as janelas do conjunto K , bem como a configuração ideal da assinatura do tipo $\vec{\Psi}$, que utiliza a concatenação de assinaturas $\vec{\Theta}$ com $Q = \{19, 39\}$. As assinaturas $\vec{\Theta}$ e $\vec{\Psi}$ têm suas configurações ideais representadas como $\vec{\Theta}(39)_{3,5,7}$ e $\vec{\Psi}_{19,39}$, respectivamente.

Considerando também o mesmo conjunto de janelas (K), as configurações recomendadas para as demais assinaturas são: $Q = 19$ para Vetor de Rótulos e Rótulos Híbridos, $Q = 59$ para Média dos Rótulos e Expansão de Características.

5.2.2 Conjunto K_2 de janelas de análise de pixels

Os resultados a seguir foram obtidos usando o conjunto de janelas $K_2 = \{5, 7, 9\}$. As Tabelas 8, 9 e 10 comparam os resultados gerados por todas as assinaturas baseadas em RNN, com marcações em negrito para os maiores valores alcançados por cada assinatura, usando o classificador LDA e validação LOO.

Tabela 8 – Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K_2 para a base de Brodatz.

Q	$\bar{\Theta}$	Taxas de Acerto por Assinatura (%)			
		Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	86,77	87,50	91,72	87,22	89,64
19	89,36	89,92	92,29	90,93	91,33
29	90,82	90,54	90,15	91,55	91,50
39	90,31	90,65	85,19	91,33	91,95
49	90,20	90,71	11,26	92,74	91,61
59	91,55	92,23	-	92,91	92,34

Tabela 9 – Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K_2 para a base Outex.

Q	$\bar{\Theta}$	Taxas de Acerto por Assinatura (%)			
		Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	81,76	80,22	84,71	80,59	83,82
19	83,01	82,50	79,26	85,07	84,93
29	82,13	82,28	64,63	83,82	85,00
39	83,01	82,57	-	85,07	81,99
49	83,23	82,13	-	83,38	80,00
59	81,25	81,69	-	85,29	77,72

As Tabelas 11, 12 e 13, a seguir, apresentam as taxas de acerto obtidas pelas assinaturas geradas com as janelas K_2 , usando validação 10-fold.

É possível observar que ao utilizar janelas com dimensões maiores, alguns dos métodos são penalizados na classificação com LDA. Isso se deve principalmente ao fato de que as dimensões das janelas influenciam diretamente na quantidade de pixels selecionados para a composição do rótulo das abordagens Vetor de Rótulos e Rótulos Híbridos. Todavia, isso não impede que os outros métodos consigam alcançar resultados satisfatórios.

Tabela 10 – Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K_2 para a base VisTex.

Q	$\vec{\Theta}$	Taxas de Acerto por Assinatura (%)			
		Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	88,31	89,24	94,21	90,28	91,20
19	91,20	91,55	76,97	93,75	94,68
29	93,17	92,82	-	94,91	93,98
39	91,43	93,63	-	95,83	93,06
49	92,36	92,48	-	95,49	90,86
59	92,71	92,94	-	96,64	85,42

Tabela 11 – Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K_2 para a base de Brodatz.

Q	Taxas de Acerto por Assinatura (%)			
	Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	90,63	95,12	88,94	93,62
19	93,05	94,55	93,23	94,17
29	91,92	93,42	93,04	93,42
39	93,24	87,80	95,31	94,74
49	94,56	0,94	96,24	95,50
59	95,30	-	96,80	95,11

Tabela 12 – Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K_2 para a base Outex.

Q	Taxas de Acerto por Assinatura (%)			
	Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	87,75	91,42	86,76	90,44
19	88,73	89,95	91,42	91,67
29	87,50	81,86	87,75	89,22
39	88,24	-	91,18	87,25
49	87,01	-	86,76	87,99
59	86,76	-	88,97	87,75

Tabela 13 – Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K_2 para a base VisTex.

Q	Taxas de Acerto por Assinatura (%)			
	Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	94,58	98,06	97,68	96,51
19	93,85	75,41	96,16	96,93
29	96,53	-	96,92	98,08
39	97,69	-	98,47	97,70
49	95,37	-	99,23	96,91
59	96,15	-	98,46	93,45

Assinaturas mais longas, como a gerada por Vetor de Rótulos, que apresentam problemas na classificação com LDA, podem ainda ser combinadas com outros tipos de classificadores. Dessa maneira, é possível calcular resultados de classificação, independentemente do número de características contidos na assinatura. Um exemplo de classificador que pode gerar tais resultados

é o K -ésimo Vizinho mais Próximo / *K-Nearest Neighbor* (K-NN).

5.3 Resultados em bases de Aplicação

As bases de imagens da Cérnix Uterina e Ligas de Titânio Ti-6Al-4V foram consideradas como bases para aferir a acurácia dos métodos propostos, com problemas práticos auxiliados por computador. Os resultados a seguir foram extraídos dessas bases utilizando as janelas K e K_2 e as configurações da seção anterior.

5.3.1 Conjunto K de janelas de análise de pixels

As taxas de acerto mostradas nas Tabelas 14 e 15 foram calculadas a partir do conjunto K de janelas, utilizando LOO como técnica de validação cruzada. Já os resultados apresentados nas Tabelas 16 e 17 exibem as taxas de acerto calculadas a partir do método de validação cruzada 10-fold.

Tabela 14 – Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K para a base Imagens da Cérnix Uterina.

Q	Taxas de Acerto por Assinatura (%)			
	Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	80,48	86,48	83,32	85,50
19	86,91	87,46	84,84	88,99
29	83,53	83,97	88,44	88,22
39	86,15	80,92	87,57	87,02
49	86,26	72,85	86,26	86,48
59	87,68	55,51	88,11	86,37

Tabela 15 – Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K para a base Ligas de Titânio Ti-6Al-4V.

Q	Taxas de Acerto por Assinatura (%)			
	Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	96,44	99,05	96,15	97,97
19	97,95	99,15	98,13	98,56
29	98,72	99,33	97,97	98,95
39	99,03	99,51	98,26	99,23
49	98,74	99,44	98,33	99,15
59	99,03	99,38	98,26	99,05

Ao observar as Tabelas 14 e 16 é possível perceber quão difícil é realizar a classificação do problema binário (células normais e células anormais) nas bases de imagem da Cérnix

Tabela 16 – Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K para a base Imagens da Cérnix Uterina.

Q	Taxas de Acerto por Assinatura (%)			
	Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	80,72	88,01	83,27	87,26
19	83,21	84,31	81,39	85,03
29	87,28	83,27	88,36	91,28
39	84,71	76,36	88,72	85,07
49	85,14	64,13	87,68	85,14
59	85,81	50,51	86,91	85,09

Tabela 17 – Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K para a base Ligas de Titânio Ti-6Al-4V.

Q	Taxas de Acerto por Assinatura (%)			
	Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	96,67	99,23	96,67	98,29
19	97,52	98,80	97,78	98,46
29	98,80	99,15	98,63	98,97
39	99,57	99,66	98,55	99,66
49	99,06	99,40	98,21	99,15
59	99,32	99,66	99,06	99,49

Uterina, com apenas um resultado acima de 90% de acerto. Para a base de Ligas de Titânio (Tabelas 15 e 17), por outro lado, a disputa pela maior acurácia é definida em casas decimais.

A discrepância no desempenho das assinaturas nas duas bases se deve a fatores como número de classes e balanceamento na distribuição das amostras por classe. Aliado a esses fatores, há também a distinção mais clara entre as classes pertencentes à base de Ligas de Titânio, o que proporciona maior separabilidade às classes dessa base.

5.3.2 Conjunto K_2 de janelas de análise de pixels

O comportamento das taxas de acerto para as bases de imagens da Cérnix Uterina e Ligas de Titânio foi também verificado quando as janelas K_2 são usadas como configuração para a geração das assinaturas. As Tabelas 18 e 19 apresentam as taxas de acerto usando validação LOO.

A validação 10-fold foi executada também para as assinaturas geradas a partir das janelas K_2 e seus resultados estão organizados nas Tabelas 20 e 21. Nota-se que mesmo com o aumento das dimensões das janelas, as taxas de acerto permanecem muito similares aos valores obtidos com as janelas K .

Os resultados apresentados nas tabelas, para ambos os conjuntos K e K_2 , mostram que as assinaturas propostas permanecem competitivas para a classificação de ambas as bases.

Tabela 18 – Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K_2 para a base Imagens da Cérvix Uterina.

Q	Taxas de Acerto por Assinatura (%)			
	Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	86,70	87,46	85,28	88,00
19	86,80	82,22	86,48	87,68
29	86,48	-	87,79	87,57
39	87,79	-	87,46	85,61
49	87,13	-	86,15	85,28
59	86,80	-	88,22	84,08

Tabela 19 – Taxas de acerto para as assinaturas baseadas em RNN, com validação LOO e janelas K_2 para a base Ligas de Titânio Ti-6Al-4V.

Q	Taxas de Acerto por Assinatura (%)			
	Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	96,41	99,41	95,85	98,13
19	96,87	99,18	97,33	98,59
29	98,13	99,26	97,44	99,10
39	98,51	99,13	97,46	99,08
49	98,64	99,08	97,92	99,28
59	98,79	98,21	98,21	99,31

Tabela 20 – Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K_2 para a base Imagens da Cérvix Uterina.

Q	Taxas de Acerto por Assinatura (%)			
	Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	84,00	89,09	84,36	86,90
19	82,11	70,45	81,04	83,22
29	85,81	-	86,90	88,73
39	85,43	-	87,62	82,17
49	85,87	-	84,06	77,90
59	85,45	-	86,53	77,80

Tabela 21 – Taxas de acerto para as assinaturas baseadas em RNN, com validação 10-fold e janelas K_2 para a base Ligas de Titânio Ti-6Al-4V.

Q	Taxas de Acerto por Assinatura (%)			
	Média dos Rótulos	Vetor de Rótulos	Expansão de Características	Rótulos Híbridos
09	97,35	99,32	96,24	98,55
19	96,75	98,72	96,75	98,38
29	98,38	99,15	98,12	98,97
39	98,80	99,06	96,58	99,32
49	98,80	99,06	98,03	99,15
59	99,23	98,21	98,38	99,40

Dessa vez, as assinaturas da base de imagens cervicais, nas duas validações, apresentaram dificuldades de superar a faixa de 90% de acurácia com o aumento de dimensão das janelas.

Com o novo conjunto K_2 empregado para as Bases de Aplicação, as taxas de acerto decresceram. O declínio, contudo, não se mostra acentuado e, embora a classificação das imagens

cervicais tenha apresentado dificuldades em superar a marca de 90% de acerto, os resultados permanecem muito próximos dos obtidos com as janelas do conjunto K . Outra observação importante é feita em relação à quantidade de neurônios utilizados para se alcançar as maiores taxas de acerto. Ao comparar as tabelas exibidas nesta seção, é possível perceber que, com o conjunto de janelas K_2 , foram empregados menos neurônios para atingir acurácias mais elevadas (destacadas em negrito nas tabelas).

5.4 Comparação com outras abordagens e análise dos resultados

A fim de verificar a robustez dos métodos propostos, é necessário compará-los com outros métodos da literatura, de modo a aferir a real capacidade discriminativa. Para a análise dos resultados foram usadas apenas as acurácias obtidas com a quantidade de neurônios ideal de cada um dos métodos, considerando ainda as diferentes dimensões de janelas (K e K_2) também conduzidas nos experimentos.

Para fornecer uma análise mais robusta, a Tabela 22 mostra as assinaturas propostas comparadas com métodos tradicionais e modernos encontrados na literatura. Para a comparação, foram considerados os seguintes descritores: Histograma de Primeira Ordem (MATERKA; STRZELECKI, 1998), descritores de Fourier (WESZKA *et al.*, 1976; AZENCOTT *et al.*, 1997), filtros de Gabor (JAIN; FARROKHNIYA, 1991; MANJUNATH; MA, 1996; DAUGMAN; DOWNING, 1998; IDRISSE; ACHEROY, 2002), GLCM (HARALICK, 1979), Transformada discreta do cosseno / *Discrete Cosine Transform* (DCT) (NG *et al.*, 1992), Matriz de diferença de níveis de cinza / *Gray-Level Difference Matrix* (GLDM) (WESZKA *et al.*, 1976; KIM; PARK, 1999), descritores baseados em Wavelets (DAUBECHIES, 1992; CHANG; KUO, 1993; RANDEN; HUSOY, 1999; JIN *et al.*, 2011), Variância de padrão binário local / *Local Binary Pattern Variance* (LBPV) (GUO *et al.*, 2010b), Padrão binário local completo / *Complete Local Binary Pattern* (CLBP) (GUO *et al.*, 2010a), Padrão ternário local / *Local Ternary Pattern* (LTP) (TAN; TRIGGS, 2007) e Descritor de Textura baseado em Redes Complexas / *Complex Network-based Texture Descriptor* (CNTD) (BACKES *et al.*, 2013). As configurações detalhadas para todos esses descritores podem ser encontradas em (SÁ JUNIOR; BACKES, 2016).

Como mostra a Tabela 22, a assinatura Média dos Rótulos ($Q = 59$) assumiu a posição de sexta melhor assinatura para a caracterização da base de Brodatz superando em 0,56% a sétima melhor abordagem (GLDM) e sendo ultrapassada pela assinatura $\vec{\Psi}_{19,39}$ (quinta melhor) em apenas 0,28%. Em Outex, a Média dos Rótulos fornece a quarta melhor taxa de acerto. Dessa

Tabela 22 – Comparação das acurácias médias das assinaturas baseadas em RNN com outros métodos. Configuração de janelas K e validação LOO.

Métodos	Taxas de Acerto (%)		
	Brodatz	Outex	VisTex
Histograma de Primeira Ordem	40,20	54,63	52,66
Fourier	75,90	81,91	79,51
Gabor	89,86	81,91	93,28
GLCM	90,43	80,73	92,24
DCT	79,11	71,25	80,09
GLDM	94,43	86,76	97,11
Wavelets	81,25	68,82	85,07
CLBP	95,32	85,80	98,03
LBPV	86,26	75,66	88,65
LTP	88,04	79,16	91,56
CNTD	95,27	86,76	98,03
$\bar{\Theta}(39)_{3,5,7}$	94,14	88,82	98,03
$\bar{\Psi}_{19,39}$	95,27	89,70	98,14
Média dos Rótulos ($Q = 59$)	94,99	90,59	98,73
Vetor de Rótulos ² ($Q = 19$)	95,38	90,96	99,07
Expansão de Características ($Q = 59$)	95,66	90,88	98,73
Rótulos Híbridos ($Q = 19$)	94,09	91,32	98,50

Fonte: As acurácias dos métodos comparados foram obtidas de Sá Junior e Backes (2016).

vez, superando a assinatura $\bar{\Psi}_{19,39}$ em 0,89% e 0,29% abaixo do resultado apresentado pela assinatura Expansão de Características ($Q = 59$). Os resultados obtidos pela Média dos Rótulos melhoram na base VisTex. Nessa base há um empate pelo segundo lugar, entre a Média dos Rótulos e a Assinatura Expansão de Características. Além disso, ambas distanciam-se em 0,23% da terceira melhor taxa de acerto, Rótulos Híbridos ($Q = 19$), e são superadas em 0,34% pela assinatura Vetor de Rótulos ($Q = 19$).

A abordagem Vetor de Rótulos ($Q = 19$) obteve o segundo melhor resultado para a base de Brodatz, superando em 0,06% a abordagem CLBP e 0,28% abaixo do resultado da Expansão de Características ($Q = 59$). Para a base Outex, Vetor de Rótulos se manteve como segunda melhor assinatura, superada em 0,36% pela assinatura de Rótulos Híbridos ($Q = 19$) e 0,08% acima da terceira melhor taxa de acerto para essa base, Expansão de Características ($Q = 59$). Na base VisTex, a assinatura Vetor de Rótulos suplantou as demais e atingiu a taxa de 99,07% de acurácia, 0,34% acima das segundas colocadas: Média dos Rótulos ($Q = 59$) e Expansão de Características ($Q = 59$).

A assinatura Expansão de Características ($Q = 59$) alcançou o melhor resultado para a classificação da base de Brodatz, ultrapassando a segunda melhor concorrente, Vetor

² Esses resultados encontram-se publicados em (LEITÃO JÚNIOR; SÁ JUNIOR, 2019), trabalho que foi produzido como parte da pesquisa contida nesta dissertação.

de Rótulos ($Q = 19$), em 0,28%. Na base Outex, a Expansão de Características apresenta a terceira melhor taxa de acerto, distanciando-se 0,29% da quarta maior taxa de acerto, obtida pela assinatura Média dos Rótulos ($Q = 59$), e 0,08% da segunda melhor concorrente, Vetor de Rótulos ($Q = 19$). Em VisTex, como já mencionado, a assinatura Expansão de Características fica em empate com a Média dos Rótulos ($Q = 59$).

Embora a assinatura de Rótulos Híbridos ($Q = 19$) tenha demonstrado um desempenho menos satisfatório para a classificação da base de Brodatz, ocupando a posição de nona melhor taxa de acerto, os resultados obtidos nas bases Outex e VisTex são mais relevantes. Em Outex, a abordagem de Rótulos Híbridos destaca-se com a melhor acurácia, superando em 0,36% o resultado da assinatura Vetor de Rótulos ($Q = 19$). O resultado dos Rótulos Híbridos na base VisTex se estabelece como quarto melhor, abaixo da Média dos Rótulos ($Q = 59$) em 0,23% e acima da assinatura $\vec{\Psi}_{19,39}$ em 0,36%.

A princípio as diferenças apresentadas entre as taxas de acerto podem não parecer tão relevantes, porém é importante enfatizar que, em uma comparação com outros 16 métodos, mesmo um avanço discreto nas taxas de acerto salienta a capacidade discriminativa que um método possui em relação a outro.

Considerando os resultados apresentados pelas assinaturas propostas neste trabalho, sob validação LOO, a assinatura Vetor de Rótulos ($Q = 19$) possui o melhor desempenho geral, ocupando as primeiras posições para a classificação das três bases de imagens referência.

Por outro lado, uma desvantagem do método Vetor de Rótulos é a alta dimensionalidade de sua assinatura ao usar janelas maiores (vide Equação 4.2 para calcular o comprimento da assinatura gerada, dadas as dimensões de janelas utilizadas), pois esse tipo de assinatura é formado pela concatenação das assinaturas obtidas para cada pixel d_i do conjunto de rótulos. No conjunto de dados VisTex, por exemplo, a assinatura criada pelo método Vetor de Rótulos com 59 neurônios não pôde ser classificada usando o LDA porque o número de características era maior que o número de amostras. O mesmo pôde ser observado ao utilizar as janelas do conjunto K_2 para as bases de Brodatz, Outex, VisTex e Imagens da Cérvix Uterina.

A segunda assinatura que apresenta melhor desempenho geral é a Expansão de Características ($Q = 59$). Essa assinatura apresenta resultados relevantes e, considerando suas altas taxas de acerto, é possível considerá-la como uma candidata à substituição da assinatura Vetor de Rótulos quando as aplicações exigirem que um número menor de descritores seja usado para a classificação de texturas. Em outras palavras, o tamanho compacto das assinaturas geradas

com o método de Expansão de Características permite que esse tipo de assinatura tenha alto poder discriminativo gerando poucos descritores como saída da RNN. Em uma comparação detalhada desse aspecto, a assinatura Vetor de Rótulos ($Q = 19$) é composta por 300 características, enquanto a Expansão de Características ($Q = 59$) possui apenas 180 características em sua composição final, isto é, uma redução de 40% da dimensionalidade.

Em relação às bases Outex e VisTex, é importante enfatizar que as cinco melhores taxas de acurácia (classificação por LDA e validação por LOO) foram obtidas por descritores baseados em RNN, com empate na base Vistex da assinatura $\vec{\Theta}(39)_{3,5,7}$ com os métodos CNTD e CLBP. Além disso, observa-se ainda que, na base Outex, a assinatura $\vec{\Theta}(39)_{3,5,7}$ (sexta colocada) obtém 2,06% a mais de acurácia em relação ao método CNTD (sétimo colocado). Esse fenômeno certamente indica o poder descritivo que as assinaturas baseadas em RNN possuem nestas bases.

Outra comparação a ser feita é a dos resultados obtidos pelos mesmos métodos acima, quando submetidos à validação 10-fold. As acurácias obtidas estão na Tabela 23.

Tabela 23 – Comparação das acurácias médias das assinaturas baseadas em RNN com outros métodos. Configuração de janelas K e validação 10-fold.

Métodos	Taxas de Acerto (%)		
	Brodatz	Outex	VisTex
Histograma de Primeira Ordem	39,35	54,85	51,74
Fourier	75,90	81,62	78,47
Gabor	89,80	81,69	93,28
GLCM	90,26	80,66	92,36
DCT	78,94	71,10	79,74
GLDM	94,59	86,98	97,22
Wavelets	80,57	69,26	84,37
CLBP	95,32	85,80	98,03
LBPV	86,26	75,66	88,65
LTP	88,04	79,16	91,56
CNTD	95,21	86,69	98,03
$\vec{\Theta}(39)_{3,5,7}$	94,20	88,82	98,14
$\vec{\Psi}_{19,39}$	95,15	89,55	98,14
Média dos Rótulos ($Q = 59$)	96,05	89,46	97,67
Vetor de Rótulos ($Q = 19$)	96,24	91,18	98,85
Expansão de Características ($Q = 59$)	96,62	91,67	97,67
Rótulos Híbridos ($Q = 19$)	94,74	93,38	98,85

Fonte: As acurácias dos métodos comparados foram obtidas de Sá Junior e Backes (2016).

Considerando os dados dispostos na Tabela 23, é possível perceber que as assinaturas baseadas em RNN permanecem na liderança dos melhores descritores para as bases de Brodatz, Outex e VisTex. Na base Outex, em particular, todas as seis assinaturas baseadas em RNN

ocupam as primeiras posições em valores de precisão, assim como observado nos resultados obtidos com a validação LOO.

Utilizando a validação 10-fold e as configurações especificadas para cada tipo de assinatura, a abordagem de Média dos Rótulos ($Q = 59$) se posicionou como terceiro melhor vetor de características para a base de Brodatz, superando em 0,73% a abordagem CLBP. Nessa mesma base, a Média dos Rótulos foi ultrapassada em 0,19% pela abordagem Vetor de Rótulos ($Q = 19$). O posicionamento da taxa de acerto da Média dos Rótulos para a base Outex decaiu. Nessa base, a Média dos Rótulos ocupa a quinta posição, atrás em 0,09% da assinatura $\vec{\Psi}_{19,39}$ e 0,64% à frente da assinatura $\vec{\Theta}(39)_{3,5,7}$. Em VisTex, a taxa de acerto dessa assinatura fica ainda menos satisfatória, levando a assinatura Média dos Rótulos à sétima colocação, em empate com a assinatura Expansão de Características ($Q = 59$), com 0,45% de acurácia à frente do descritor GLDM e 0,36% atrás da assinatura concorrente CLBP.

Já a assinatura Vetor de Rótulos ($Q = 19$), forneceu resultados satisfatórios nas três Bases de Referência. Em Brodatz ocupou o segundo lugar, superando em 0,19% a Média dos Rótulos ($Q = 59$) e suplantada pela Expansão de Características ($Q = 59$) em 0,38%. Na base de imagens Outex, posicionou-se com a terceira melhor taxa de acerto, superando a assinatura $\vec{\Psi}_{19,39}$ em 1,63% e tendo resultado inferior ao da abordagem de Expansão de Características ($Q = 59$) em 0,49%. Na base VisTex houve um empate pela melhor acurácia, alcançada tanto pelo Vetor de Rótulos como também pela assinatura dos Rótulos Híbridos ($Q = 19$). Entretanto, como critério de desempate para este caso, o número de descritores penalizou novamente a assinatura Vetor de Rótulos, uma vez que a abordagem de Rótulos Híbridos produz uma assinatura com menor número de características. Assim, é possível estabelecer que, para a base VisTex, a assinatura Vetor de Rótulos ($Q = 19$) é a abordagem com o segundo melhor desempenho de classificação, superando em 0,71% as assinaturas $\vec{\Theta}(39)_{3,5,7}$ e $\vec{\Psi}_{19,39}$.

Novamente, a Expansão de Características ($Q = 59$) destacou-se na classificação de Brodatz, assim como observado na Tabela 22, com os resultados da classificação validados por LOO. Em Brodatz, a assinatura de Expansão de Características foi seguida pelo Vetor de Rótulos ($Q = 19$), com 0,38% de diferença nas acurácias alcançadas. Para a base Outex, a Expansão de Características teve a segunda melhor taxa de acerto, sendo superada pela assinatura de Rótulos Híbridos ($Q = 19$) com 1,71% de diferença e superando a assinatura do Vetor de Rótulos ($Q = 19$) por 0,49%. O resultado logrado pela Expansão de Características na base VisTex, no entanto, colocou-a em sétima posição, em empate com a Média dos Rótulos ($Q = 59$).

A assinatura de Rótulos Híbridos ($Q = 19$) apresentou a sétima melhor taxa de acerto, validada por 10-fold, para a base de Brodatz, superada em 0,41% pela assinatura $\vec{\Psi}_{19,39}$ e seguida pelo descritor GLDM com 0,15% de diferença de acurácia. Nas outras bases de imagens, por outro lado, a assinatura de Rótulos Híbridos suplantou todos os demais métodos de caracterização de texturas, imediatamente seguida pela assinatura Expansão de Características ($Q = 19$) em Outex, com diferença de 1,71% na taxa de acerto; e sucedida pela Vetor de Rótulos ($Q = 19$) em VisTex. Como dito anteriormente, a assinatura de Rótulos de Híbridos e Vetor de Rótulos alcançaram igual taxa de acerto na base de imagens VisTex. Porém, é seguro afirmar que a assinatura de Rótulos Híbridos tem melhor desempenho quando considerada a relação entre o resultado alcançado e a dimensão do vetor de características utilizado. A assinatura Vetor de Rótulos ($Q = 19$) é composta por 300 características para cada imagem. A assinatura de Rótulos Híbridos utiliza 120 características, representando uma redução de 60%.

Os resultados obtidos com a validação 10-fold mostram que a assinatura de Rótulos Híbridos ($Q = 19$) obteve o melhor desempenho geral, com destaque na classificação das bases Outex e VisTex. A assinatura Vetor de Rótulos ($Q = 19$) vem em seguida, mantendo bom posicionamento na classificação de todas as bases.

É importante notar que o tipo de assinatura Rótulos Híbridos representa uma mescla das abordagens do Vetor de Rótulos e Média dos Rótulos, caracterizando, portanto, uma assinatura de comprimento maior que a gerada pela Média dos Rótulos e menor que a quantidade de descritores fornecidos pelo Vetor de Rótulos. Esses resultados demonstram que a assinatura mantém ainda uma boa separabilidade dos dados e é uma boa conciliação entre poder de discriminação e quantidade de descritores produzidos, sendo uma boa candidata para a substituição da assinatura de Vetor de Rótulos em contextos que precisem de menor dimensionalidade no vetor de características usado.

Os resultados obtidos na base VisTex, sob a validação 10-fold, salientam um padrão nos resultados das assinaturas. Considerando a arquitetura empregada na obtenção de cada assinatura, pode-se afirmar que as assinaturas Vetor de Rótulos e Rótulos Híbridos possuem similaridades no que diz respeito ao uso de mais pixels na composição do rótulo. Isto pode ser um indício de que para aumentar a capacidade discriminativa da abordagem introduzida por Sá Junior e Backes (2016), a chave não esteja em considerar mais pixels como características mas, sim, trabalhar a informação geradora do rótulo em relação às características de cada janela analisada.

Como última etapa da comparação com outros métodos, os resultados das assinaturas propostas serão comparados com outros métodos da literatura que trabalharam na classificação das bases de imagens da Cérvix Uterina e Ligas de Titânio Ti-6Al-4V.

Para essas análises, foi reduzida a quantidade de métodos de comparação para simplificação da análise e, em relação às assinaturas propostas por Sá Junior e Backes (2016), será utilizada apenas a assinatura de tipo $\vec{\Psi}_{19,39}$, tendo em vista de que ela possui maior poder descritivo quando comparada à assinatura $\vec{\Theta}(39)_{3,5,7}$. Note ainda que a assinatura $\vec{\Psi}_{19,39}$ é formada pela concatenação das assinaturas $\vec{\Theta}(19)_{3,5,7}$ e $\vec{\Theta}(39)_{3,5,7}$, portanto, a configuração de janelas de análise de pixels nas comparações foram restritas ao conjunto $K = \{3, 5, 7\}$. Em ambas as bases foi aplicada a classificação utilizando LDA e LOO como método de validação cruzada.

Tabela 24 – Comparação das acurácias médias das assinaturas baseadas em RNN com outros métodos, nas bases de Imagens da Cérvix Uterina e Ligas de Titânio Ti-6Al-4V com validação LOO.

Métodos	Taxas de Acerto (%)	
	Imagens da Cérvix Uterina	Ligas de Titânio Ti-6Al-4V
Wavelet	86,37	88,90
Caminhada do Turista	85,82	86,00
GLCM	79,83	86,26
$\vec{\Psi}_{19,39}$	87,57	98,84
Média dos Rótulos ($Q = 59$)	87,68	99,03
Vetor de Rótulos ($Q = 19$)	87,46	99,15
Expansão de Características ($Q = 59$)	88,11	98,26
Rótulos Híbridos ($Q = 19$)	88,99	98,56

Fonte: As acurácias dos métodos comparados foram obtidas de Sá Junior *et al.* (2018a) e Sá Junior *et al.* (2018b)

Para a comparação, foram considerados os seguintes descritores: GLCM (HARALICK, 1979), descritores baseados em Wavelets (DAUBECHIES, 1992; CHANG; KUO, 1993; RANDEN; HUSOY, 1999; JIN *et al.*, 2011) e descritores baseados em Caminhada do Turista (BACKES *et al.*, 2010). As configurações detalhadas para todos esses descritores podem ser encontradas em (SÁ JUNIOR *et al.*, 2018b).

De acordo com a Tabela 24, os descritores que assumem a liderança nas taxas de acerto de classificação das bases da Cérvix Uterina e Ligas de Titânio são as assinaturas Rótulos Híbridos ($Q = 19$) e Vetor de Rótulos ($Q = 19$), respectivamente.

A assinatura Vetor de Rótulos ($Q = 19$) apresenta 0,12% de diferença de percentual da taxa de acerto em relação ao segundo melhor descritor, Média dos Rótulos ($Q = 59$). Em

relação à base de imagens de exames de Papanicolau, a abordagem de Vetor de Rótulos fica em quinto lugar, sendo inferior à assinatura $\vec{\Psi}_{19,39}$ com 0,11% de diferença, e à frente da sexta melhor assinatura (Wavelet) com 1,09% de diferença.

Considerando a assinatura de Rótulos Híbridos ($Q = 19$) aplicada na base de Imagens da Cérvix Uterina, a comparação mostra que esse descritor ultrapassou em 0,88% o segundo melhor descritor, Expansão de Características ($Q = 59$). Esse resultado é, sem dúvida, um resultado importante, embora a diferença seja pequena. Isso porque essa base de imagens é, dentre todas as bases usadas neste trabalho, a coleção de imagens mais difícil de distinguir as amostras dentre as classes, não só para humanos especialistas como também para os algoritmos mais robustos de extração de características. Para a base de Ligas de Titânio, a abordagem de Rótulos Híbridos também alcançou bons resultados, colocando-se em quarto lugar.

Destaque também pode ser dado à assinatura de Média dos Rótulos ($Q = 59$), devido às suas colocações nessas bases. Essa assinatura ocupou a terceira melhor posição para a classificação das imagens de exames de Papanicolau e produziu a segunda melhor taxa de acerto na classificação das imagens de Ligas de Titânio. O desempenho da assinatura de Média dos Rótulos para essas bases de imagens a qualifica como alternativa indicada para substituição da assinatura de Vetor de Rótulos, uma vez que ela consegue alta capacidade discriminativa com um menor comprimento de assinatura.

6 CONCLUSÕES

Neste trabalho foram propostos métodos alternativos para a extração de características de texturas baseados em RNN. As alternativas propostas foram criadas para incrementar o descritor apresentado por Sá Junior e Backes (2016), observando a questão da perda de correlação dos valores de pixels selecionados para compor a borda e o núcleo das janelas de análise, responsáveis pela produção dos descritores finais.

Os resultados apresentados mostram que as quatro abordagens propostas para a construção de assinaturas baseadas em RNN possuem capacidades discriminativas e contribuem para a produção de assinaturas mais robustas, contemplando mais informações de uma mesma janela de análise, seja por um novo esquema de seleção de pixels para a composição do núcleo, seja pela ampliação do número de pixels selecionados como características. Em ambos os casos, mais informações das janelas são aproveitadas para a construção de assinaturas mais discriminativas.

Dentre as abordagens apresentadas, duas recebem maior destaque. São elas a abordagem do Vetor de Rótulos ($Q = 19$) e a de Expansão de Características ($Q = 59$), imediatamente seguidas pela abordagem de Rótulos Híbridos ($Q = 19$) e, por fim, Média dos Rótulos ($Q = 59$).

O Vetor de Rótulos, possui uma estrutura baseada na construção de vários vetores de características simultaneamente para uma mesma imagem, concatenando-os ao final e gerando uma assinatura poderosa. Entretanto, esta também é sua desvantagem, pois as assinaturas podem tornar-se longas, impedindo que sejam usadas em determinados casos.

A assinatura por Expansão de Características é uma assinatura capaz de alcançar elevadas taxas de acerto, utilizando um vetor de características menor. Essa abordagem utiliza um número maior de pixels no entorno do pixel central, considerando mais informações de uma janela analisada e mantendo um único rótulo para todas essas características adicionais. Ao fim do processo de geração da assinatura pela RNN, o vetor de características produzido se torna mais compacto.

A abordagem de Rótulos Híbridos mostrou-se um bom meio-termo entre a numerosa quantidade de características geradas pelo Vetor de Rótulos e a compactação da informação do núcleo de uma janela de pixels por parte da Média dos Rótulos. Essa assinatura mostrou-se relevante para a solução de problemas reais como observado nos experimentos com as bases de Imagens da Cérvix Uterina, uma coleção de imagens difícil de classificar, mesmo para humanos especialistas ou para os métodos mais robustos da literatura.

A Média dos Rótulos, assim como a Expansão de Características, é uma abordagem com foco na menor dimensionalidade do vetor de características gerado pela RNN. Essa assinatura também possui resultados relevantes e demonstra que as informações no entorno do pixel central de uma janela analisada podem também ser utilizados de maneira conjunta como uma maneira de caracterizar a textura sem, necessariamente, envolver todos os pixels do centro da janela como rótulos.

Observando os resultados das tabelas das Subseções 5.2.2 e 5.3.2, é possível perceber que as assinaturas propostas também conseguiram atingir o objetivo de se manterem robustas com o aumento da dimensão das janelas analisadas. No experimento foram usadas as janelas $K_2 = \{5, 7, 9\}$ em todas as bases. Os resultados demonstram que mesmo ao usar janelas de dimensões maiores, os descritores produzidos são ainda bastante competitivos.

Por fim, ao comparar as assinaturas propostas com outros métodos tradicionais ou modernos encontrados na literatura, conclui-se que as assinaturas apresentadas neste trabalho superam a maioria das abordagens concorrentes. Isso mostra que as assinaturas contribuem com o estado da arte na área de análise de texturas e são alternativas viáveis para aplicações de classificação de texturas.

6.1 Trabalhos Publicados

Durante o desenvolvimento da pesquisa apresentada nesta dissertação algumas abordagens de extração de características, assim como os primeiros resultados, foram publicados em um trabalho apresentado no XV Workshop de Visão Computacional (WVC), um evento nacional dedicado especialmente para a congregação da comunidade de pesquisadores em visão computacional e para a discussão de estudos e avanços nessa área.

O trabalho, publicado sob o título *Alternative Signatures based on Randomized Neural Network for Texture Classification* (LEITÃO JÚNIOR; SÁ JUNIOR, 2019), contemplou somente as abordagens de Média dos Rótulos e Vetor de Rótulos, apresentando-as ao meio científico como propostas viáveis para a caracterização de texturas em imagens digitais. Também foram demonstrados os resultados preliminares dos métodos aplicados à descrição das bases de Brodatz, Outex e VisTex, em comparação a outros descritores disponíveis na literatura.

Vale ressaltar ainda que essa publicação conquistou a premiação de melhor trabalho apresentado na modalidade pôster, competindo com outros trabalhos também relevantes e relacionados a aplicações diversas em visão computacional.

6.2 Trabalhos Futuros

Como trabalhos futuros, pesquisas podem ser desenvolvidas com o objetivo de extrair ainda mais informação das janelas de pixels analisadas pelos geradores de assinatura propostos, incluindo ou removendo pixels no momento de construir a matriz de vetores de características e de rótulos, que serão submetidos à RNN. Esse estudo é importante para delimitar o limiar do quanto a informação selecionada colabora com a melhora ou piora da representação das texturas, encontrando assim um meio-termo que permita alcançar maior capacidade discriminativa com um número reduzido de características.

Nos estudos de análise de textura existem ainda outras questões que podem ser exploradas nas abordagens propostas, como a robustez à rotação e escala das imagens apresentadas aos geradores de assinatura. Considerar essas características com experimentos amplamente realizados na literatura permitirão verificar essas qualidades da assinatura e trabalhar para a sua melhoria. O trabalho de Sá Junior e Backes (2016) apresenta ainda experimentos com as bases de Brodatz, Outex e VisTex rotacionadas e permite um parâmetro de comparação com outras assinaturas baseadas em RNN.

REFERÊNCIAS

- ARIVAZHAGAN, S.; GANESAN, L. Texture classification using wavelet transform. **Pattern Recogn. Lett.**, Elsevier Science Inc., New York, NY, USA, v. 24, n. 9-10, p. 1513–1521, jun. 2003. ISSN 0167-8655.
- AZAMI, H.; ESCUDERO, J.; HUMEAU-HEURTIER, A. Bidimensional distribution entropy to analyze the irregularity of small-sized textures. **IEEE Signal Processing Letters**, v. 24, n. 9, p. 1338–1342, Sep. 2017.
- AZENCOTT, R.; WANG, J.-P.; YOUNES, L. Texture classification using windowed Fourier filters. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 19, n. 2, p. 148–153, Feb 1997. ISSN 0162-8828.
- BACKES, A. R.; CASANOVA, D.; BRUNO, O. M. Plant leaf identification based on volumetric fractal dimension. **International Journal of Pattern Recognition and Artificial Intelligence**, v. 23, n. 06, p. 1145–1160, 2009.
- BACKES, A. R.; CASANOVA, D.; BRUNO, O. M. Color texture analysis based on fractal descriptors. **Pattern Recognition**, v. 45, n. 5, p. 1984 – 1992, 2012. ISSN 0031-3203.
- BACKES, A. R.; CASANOVA, D.; BRUNO, O. M. Texture analysis and classification: A complex network-based approach. **Information Sciences**, v. 219, p. 168 – 180, 2013. ISSN 0020-0255.
- BACKES, A. R.; GONÇALVES, W. N.; MARTINEZ, A. S.; BRUNO, O. M. Texture analysis and classification using deterministic tourist walk. **Pattern Recognition**, v. 43, n. 3, p. 685 – 694, 2010. ISSN 0031-3203.
- BACKES, A. R.; SÁ JUNIOR, J. J. M. **Introdução à Visão Computacional usando Matlab**. Rio de Janeiro, RJ: Alta Books, 2016. ISBN 978-85-508-0023-3.
- BORA, K.; CHOWDHURY, M.; MAHANTA, L. B.; KUNDU, M. K.; DAS, A. K. Automated classification of pap smear images to detect cervical dysplasia. **Computer Methods and Programs in Biomedicine**, v. 138, p. 31 – 47, 2017. ISSN 0169-2607. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0169260716303583>>.
- BRAZ JUNIOR, G.; PAIVA, A. C. de; SILVA, A. C.; OLIVEIRA, A. C. M. de. Classification of breast tissues using moran's index and geary's coefficient as texture signatures and svm. **Computers in Biology and Medicine**, v. 39, n. 12, p. 1063 – 1072, 2009. ISSN 0010-4825.
- BRODATZ, P. Textures: A photographic album for artists and designers. **Dover Publications**, New York, NY, USA, 1966.
- BRUSCHI, S.; POGGIO, S.; QUADRINI, F.; TATA, M. Workability of Ti–6Al–4V alloy at high temperatures and strain rates. **Materials Letters**, v. 58, n. 27, p. 3622 – 3629, 2004. ISSN 0167-577X. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167577X04005142>>.
- CHANG, T.; KUO, C. . J. Texture analysis and classification with tree-structured wavelet transform. **IEEE Transactions on Image Processing**, v. 2, n. 4, p. 429–441, Oct 1993. ISSN 1057-7149.

CHEN, Y.; DOUGHERTY, E. R. Gray-scale morphological granulometric texture classification. **Optical Engineering**, v. 33, n. 8, p. 2713 – 2722, 1994. Disponível em: <<https://doi.org/10.1117/12.173552>>.

COGGINS, J. M. **A Framework for Texture Analysis Based on Spatial Filtering**. Tese (Doutorado), East Lansing, MI, USA, 1982. AAI8315444.

DAUBECHIES, I. **Ten Lectures on Wavelets**. Philadelphia, PA, USA: Society for Industrial and Applied Mathematics, 1992. ISBN 0-89871-274-2.

DAUGMAN, J.; DOWNING, C. Gabor wavelets for statistical pattern recognition. In: ARBIB, M. A. (Ed.). **The Handbook of Brain Theory and Neural Networks**. Cambridge, MA, USA: MIT Press, 1998. p. 414–420. ISBN 0-262-51102-9.

DUCATO, A.; FRATINI, L.; CASCIA, M. L.; MAZZOLA, G. An automated visual inspection system for the classification of the phases of Ti-6Al-4V titanium alloy. In: . [S.l.: s.n.], 2013. p. 362–369.

EVERITT, B. S.; DUNN, G. *et al.* **Applied multivariate data analysis**. [S.l.]: Wiley Online Library, 2001. v. 2.

FARROKHANIA, F. **Multi-channel Filtering Techniques for Texture Segmentation and Surface Quality Inspection**. Tese (Doutorado), 1990.

FISHER, R. A. The use of multiple measurements in taxonomic problems. **Annals of Eugenics**, v. 7, n. 7, p. 179–188, 1936.

FUKUNAGA, K. **Introduction to Statistical Pattern Recognition (2Nd Ed.)**. San Diego, CA, USA: Academic Press Professional, Inc., 1990. ISBN 0-12-269851-7.

GONZALEZ, R. C.; WOODS, R. C. **Digital Image Processing**. 3rd. ed. [S.l.]: Pearson Prentice Hall, 2010.

GUO, Z.; ZHANG, L.; ZHANG, D. A completed modeling of local binary pattern operator for texture classification. **IEEE Transactions on Image Processing**, v. 19, n. 6, p. 1657–1663, June 2010. ISSN 1057-7149.

GUO, Z.; ZHANG, L.; ZHANG, D. Rotation invariant texture classification using lbp variance (lbpv) with global matching. **Pattern Recognition**, v. 43, n. 3, p. 706 – 719, 2010. ISSN 0031-3203.

HARALICK, R. M. Statistical and structural approaches to texture. **Proceedings of the IEEE**, v. 67, n. 5, p. 786–804, May 1979. ISSN 0018-9219.

HARALICK, R. M.; STERNBERG, S. R.; ZHUANG, X. Image analysis using mathematical morphology. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, PAMI-9, n. 4, p. 532–550, July 1987.

HAYKIN, S. S. **Neural networks and learning machines**. 3rd. ed. Upper Saddle River, NJ: Pearson Education, 2009.

HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: Theory and applications. **Neurocomputing**, v. 70, n. 1, p. 489 – 501, 2006. ISSN 0925-2312. Neural Networks.

HUMEAU-HEURTIER, A. Texture feature extraction methods: A survey. **IEEE Access**, v. 7, p. 8975–9000, 2019.

IDRISSA, M.; ACHEROY, M. Texture classification using gabor filters. **Pattern Recognition Letters**, v. 23, n. 9, p. 1095 – 1102, 2002. ISSN 0167-8655.

JAIN, A. K.; FARROKHANIA, F. Unsupervised texture segmentation using gabor filters. **Pattern Recognition**, v. 24, n. 12, p. 1167 – 1186, 1991. ISSN 0031-3203.

JANTZEN, J.; NORUP, J.; DOUNIAS, G.; BJERREGAARD, B. Pap-smear benchmark data for pattern classification. **Nature Inspired Smart Information Systems (NiSIS)**, 01 2005.

JIN, X.; GUPTA, S.; MUKHERJEE, K.; RAY, A. Wavelet-based feature extraction using probabilistic finite state automata for pattern classification. **Pattern Recognition**, v. 44, n. 7, p. 1343 – 1356, 2011. ISSN 0031-3203.

KAPLAN, L. M. Extended fractal analysis for texture classification and segmentation. **IEEE Transactions on Image Processing**, v. 8, n. 11, p. 1572–1585, Nov 1999. ISSN 1057-7149.

KIM, J. K.; PARK, H. W. Statistical textural features for detection of microcalcifications in digitized mammograms. **IEEE Transactions on Medical Imaging**, v. 18, n. 3, p. 231–238, March 1999. ISSN 0278-0062.

LAZEBNIK, S.; SCHMID, C.; PONCE, J. Beyond bags of features: Spatial pyramid matching for recognizing natural scene categories. In: **2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06)**. [S.l.: s.n.], 2006. v. 2, p. 2169–2178.

LEHMER, D. H. Mathematical methods in large-scale computing units. In: **Proceedings of the Second Symposium on Large Scale Digital Computing Machinery**. Cambridge, United Kingdom: Harvard University Press, 1951. p. 141–146.

LEITÃO JÚNIOR, M. M.; SÁ JUNIOR, J. J. M. Alternative signatures based on randomized neural network for texture classification. In: **2019 XV Workshop de Visão Computacional (WVC)**. [s.n.], 2019. p. 61–65. Disponível em: <<https://doi.org/10.1109/WVC.2019.8876952>>.

LIU, L.; CHEN, J.; FIEGUTH, P.; ZHAO, G.; CHELLAPPA, R.; PIETIKÄINEN, M. From bow to cnn: Two decades of texture representation for texture classification. **International Journal of Computer Vision**, v. 127, n. 1, p. 74–109, Jan 2019. ISSN 1573-1405. Disponível em: <<https://doi.org/10.1007/s11263-018-1125-z>>.

LLADÓ, X.; OLIVER, A.; FREIXENET, J.; MARTÍ, R.; MARTÍ, J. A textural approach for mass false positive reduction in mammography. **Computerized Medical Imaging and Graphics**, v. 33, n. 6, p. 415 – 422, 2009. ISSN 0895-6111.

MAJUMDAR, J. D.; MANNA, I. 21 - laser surface engineering of titanium and its alloys for improved wear, corrosion and high-temperature oxidation resistance. In: LAWRENCE, J.; WAUGH, D. (Ed.). **Laser Surface Engineering**. Woodhead Publishing, 2015, (Woodhead Publishing Series in Electronic and Optical Materials). p. 483 – 521. ISBN 978-1-78242-074-3. Disponível em: <<http://www.sciencedirect.com/science/article/pii/B9781782420743000210>>.

MANJUNATH, B. S.; MA, W. Y. Texture features for browsing and retrieval of image data. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 18, n. 8, p. 837–842, Aug 1996. ISSN 0162-8828.

MATERKA, A.; STRZELECKI, M. Texture analysis methods - a review. **COST B11 report**, 01 1998.

NANNI, L.; LUMINI, A.; BRAHNAM, S. Local binary patterns variants as texture descriptors for medical image analysis. **Artificial Intelligence in Medicine**, v. 49, n. 2, p. 117 – 125, 2010. ISSN 0933-3657. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0933365710000278>>.

NG, I.; TAN, T.; KITTLER, J. On local linear transform and gabor filter representation of texture. In: **Proceedings., 11th IAPR International Conference on Pattern Recognition. Vol. III. Conference C: Image, Speech and Signal Analysis.**, [S.l.: s.n.], 1992. p. 627–631.

OJALA, T.; MAENPAA, T.; PIETIKAINEN, M.; VIERTOLA, J.; KYLLONEN, J.; HUOVINEN, S. Outex - new framework for empirical evaluation of texture analysis algorithms. In: **Object recognition supported by user interaction for service robots.** [S.l.: s.n.], 2002. v. 1, p. 701–706 vol.1. ISSN 1051-4651.

OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 24, n. 7, p. 971–987, Jul 2002. ISSN 0162-8828.

PAO, Y. .; TAKEFUJI, Y. Functional-link net computing: theory, system architecture, and functionalities. **Computer**, v. 25, n. 5, p. 76–79, May 1992. ISSN 0018-9162.

PAO, Y.-H.; PARK, G.-H.; SOBAJIC, D. J. Learning and generalization characteristics of the random vector functional-link net. **Neurocomputing**, v. 6, n. 2, p. 163 – 180, 1994. ISSN 0925-2312. Backpropagation, Part IV.

PARK, S. K.; MILLER, K. W. Random number generators: Good ones are hard to find. **Commun. ACM**, ACM, New York, NY, USA, v. 31, n. 10, p. 1192–1201, out. 1988. ISSN 0001-0782.

PETRAS, K.; OEVER, S. ten; JACOBS, C.; GOFFAUX, V. Coarse-to-fine information integration in human vision. **NeuroImage**, v. 186, p. 103 – 112, 2019. ISSN 1053-8119. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1053811918320706>>.

PICARD, R.; GRACZYK, C.; MANN, S.; WACHMAN, J.; PICARD, L.; CAMPBELL, L. **VisTex vision texture database.** 2009. Disponível em: <<https://vismod.media.mit.edu/vismod/imagery/VisionTexture/vistex.html>>.

PLISSITI, M. E.; NIKOU, C.; CHARCHANTI, A. Combining shape, texture and intensity features for cell nuclei extraction in pap smear images. **Pattern Recognition Letters**, v. 32, n. 6, p. 838 – 853, 2011. ISSN 0167-8655. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167865511000171>>.

PRATT, W. K. **Digital Image Processing.** New York, NY, USA: Wiley, 1991.

RANDEN, T.; HUSOY, J. H. Filtering for texture classification: a comparative study. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 21, n. 4, p. 291–310, April 1999. ISSN 0162-8828.

ROSENFELD, A.; KAK, A. C. **Digital Picture Processing: Volume 1.** 2nd. ed. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1982. ISBN 9780323139915.

- SÁ JUNIOR, J. J. M.; BACKES, A. R. A simplified gravitational model to analyze texture roughness. **Pattern Recognition**, v. 45, n. 2, p. 732 – 741, 2012. ISSN 0031-3203.
- SÁ JUNIOR, J. J. M.; BACKES, A. R. A color texture analysis method based on a gravitational approach for classification of the pap-smear database. In: **2014 IEEE International Conference on Image Processing (ICIP)**. [S.l.: s.n.], 2014. p. 2280–2284.
- SÁ JUNIOR, J. J. M.; BACKES, A. R. ELM based signature for texture classification. **Pattern Recognition**, v. 51, p. 395 – 401, 2016. ISSN 0031-3203.
- SÁ JUNIOR, J. J. M.; BACKES, A. R.; BRUNO, O. M. Pap-smear image classification using randomized neural network based signature. In: MENDOZA, M.; VELASTÍN, S. (Ed.). **Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications**. Cham: Springer International Publishing, 2018. p. 677–684. ISBN 978-3-319-75193-1.
- SÁ JUNIOR, J. J. M.; BACKES, A. R.; BRUNO, O. M. Randomized neural network based signature for classification of titanium alloy microstructures. In: MENDOZA, M.; VELASTÍN, S. (Ed.). **Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications**. Cham: Springer International Publishing, 2018. p. 669–676. ISBN 978-3-319-75193-1.
- SÁ JUNIOR, J. J. M.; CORTEZ, P. C.; BACKES, A. R. Color texture classification using shortest paths in graphs. **IEEE Transactions on Image Processing**, v. 23, n. 9, p. 3751–3761, Sept 2014. ISSN 1057-7149.
- SCHMIDT, W. F.; KRAAIJVELD, M. A.; DUIN, R. P. W. Feedforward neural networks with random weights. In: **Proceedings., 11th IAPR International Conference on Pattern Recognition. Vol.II. Conference B: Pattern Recognition Methodology and Systems**. [S.l.: s.n.], 1992. p. 1–4.
- SENGUR, A.; TURKOGLU, I.; INCE, M. C. Wavelet packet neural networks for texture classification. **Expert Systems with Applications**, v. 32, n. 2, p. 527 – 533, 2007. ISSN 0957-4174.
- SERRA, J. **Image Analysis and Mathematical Morphology**. Orlando, FL, USA: Academic Press, Inc., 1983. ISBN 0126372403.
- SHI, J.; HUA, C.; LI, G. A simplifying method of vision attention simulating human vision in machine vision system. In: **2010 International Conference on Machine Learning and Cybernetics**. [S.l.: s.n.], 2010. v. 6, p. 3097–3100. ISSN 2160-1348.
- SILVA, L. E.; DUQUE, J. J.; FELIPE, J. C.; JR, L. O. M.; HUMEAU-HEURTIER, A. Two-dimensional multiscale entropy analysis: Applications to image texture evaluation. **Signal Processing**, v. 147, p. 224 – 232, 2018. ISSN 0165-1684. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0165168418300513>>.
- SILVA, L. E. V.; FILHO, A. C. S. S.; FAZAN, V. P. S.; FELIPE, J. C.; JUNIOR, L. O. M. Two-dimensional sample entropy: assessing image texture through irregularity. **Biomedical Physics & Engineering Express**, IOP Publishing, v. 2, n. 4, p. 045002, jul 2016. Disponível em: <<https://doi.org/10.1088%2F2057-1976%2F2%2F4%2F045002>>.

- SILVA, P. M.; FLORINDO, J. B. A statistical descriptor for texture images based on the box counting fractal dimension. **Physica A: Statistical Mechanics and its Applications**, v. 528, p. 121469, 2019. ISSN 0378-4371. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378437119308556>>.
- TAMURA, H.; MORI, S.; YAMAWAKI, T. Textural features corresponding to visual perception. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 8, n. 6, p. 460–473, June 1978.
- TAN, X.; TRIGGS, B. Enhanced local texture feature sets for face recognition under difficult lighting conditions. In: ZHOU, S. K.; ZHAO, W.; TANG, X.; GONG, S. (Ed.). **Analysis and Modeling of Faces and Gestures**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p. 168–182. ISBN 978-3-540-75690-3.
- THOMAS, W.; NICHOLAS, E.; NEEDHAM, J.; MURCH, M.; TEMPLE-SMITH, P.; DAWES, C. International patent application pct/gb92/02203 and gb patent application 9125978.8. **UK Patent Office, London**, v. 6, 1991.
- TUCERYAN, M.; JAIN, A. K. Handbook of pattern recognition & computer vision. In: CHEN, C. H.; PAU, L. F.; WANG, P. S. P. (Ed.). River Edge, NJ, USA: World Scientific Publishing Co., Inc., 1993. cap. Texture Analysis, p. 235–276. ISBN 981-02-1136-8. Disponível em: <<http://dl.acm.org/citation.cfm?id=178866.178899>>.
- VAHEDPOOR, Z.; BEHRASHI, M.; KHAMEHCHIAN, T.; ABEDZADEH-KALAHROUDI, M.; MORAVVEJI, A.; MOHMADI-KARTALAYI, M. Comparison of the diagnostic value of the visual inspection with acetic acid (via) and pap smear in cervical cancer screening. **Taiwanese Journal of Obstetrics and Gynecology**, v. 58, n. 3, p. 345 – 348, 2019. ISSN 1028-4559. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1028455919300762>>.
- WESZKA, J. S.; DYER, C. R.; ROSENFELD, A. A comparative study of texture measures for terrain classification. **IEEE Transactions on Systems, Man, and Cybernetics**, SMC-6, n. 4, p. 269–285, April 1976. ISSN 0018-9472.
- WILLIAM, W.; WARE, A.; BASAZA-EJIRI, A. H.; OBUNGOLOCH, J. Cervical cancer classification from pap-smears using an enhanced fuzzy c-means algorithm. **Informatics in Medicine Unlocked**, v. 14, p. 23 – 33, 2019. ISSN 2352-9148. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S2352914818302478>>.
- XU, J.; ZHU, J.; FAN, J.; ZHOU, Q.; PENG, Y.; GUO, S. Microstructure and mechanical properties of Ti–6Al–4V alloy fabricated using electron beam freeform fabrication. **Vacuum**, v. 167, p. 364 – 373, 2019. ISSN 0042-207X. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0042207X19310358>>.
- XU, Y.; JI, H.; FERMÜLLER, C. Viewpoint invariant texture description using fractal analysis. **International Journal of Computer Vision**, v. 83, n. 1, p. 85–100, Jun 2009. ISSN 1573-1405. Disponível em: <<https://doi.org/10.1007/s11263-009-0220-6>>.
- YEH, J.; LIN, C.; SHIEH, J. An approach of multiscale complexity in texture analysis of lymphomas. **IEEE Signal Processing Letters**, v. 18, n. 4, p. 239–242, April 2011.
- ZUCKER, S. W.; KANT, K. Multiple-level representations for texture discrimination. **IEEE Conference on Pattern Recognition and Image Processing**, Dallas, TX, p. 609–614, 1981.