Métodos de pré-processamento de texturas para otimizar o reconhecimento de padrões

Mariane Barros Neiva

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Mariane Barros Neiva

Métodos de pré-processamento de texturas para otimizar o reconhecimento de padrões

Dissertação apresentada ao Instituto de Ciências Matemáticas e de Computação – ICMC-USP, como parte dos requisitos para obtenção do título de Mestra em Ciências – Ciências de Computação e Matemática Computacional. *VERSÃO REVISADA*

Área de Concentração: Ciências de Computação e Matemática Computacional

Orientador: Prof. Dr. Odemir Martinez Bruno

USP – São Carlos
Setembro de 2016

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados fornecidos pelo(a) autor(a)

N634m Neiva, Mariane Barros
 Métodos de pré-processamento de texturas para
 otimizar o reconhecimento de padrões / Mariane
 Barros Neiva; orientador Odemir Martinez Bruno. -
 São Carlos - SP, 2016.
 141 p.

 Dissertação (Mestrado - Programa de Pós-Graduação
 em Ciências de Computação e Matemática Computacional)
 - Instituto de Ciências Matemáticas e de Computação,
 Universidade de São Paulo, 2016.

 1. Textura. 2. Pré-processamento de Imagens.
 3. Reconhecimento de Padrões. 4. Difusão
 Anisotrópica. 5. Difusão Morfológica. 6. Difusão
 Isotrópica. 7. Transformada da Distância. I. Bruno,
 Odemir Martinez, orient. II. Título.

Mariane Barros Neiva

Texture preprocessing methods to optimize pattern recognition

Master dissertation submitted to the Instituto de
Ciências Matemáticas e de Computação – ICMC-
USP, in partial fulfillment of the requirements for the
degree of the Master Program in Computer Science
and Computational Mathematics. *FINAL VERSION*

Concentration Area: Computer Science and
Computational Mathematics

Advisor: Prof. Dr. Odemir Martinez Bruno

USP – São Carlos
September 2016

Dedico esse trabalho ao meu pai, que sempre ensinou que a melhor herança é o conhecimento.

AGRADECIMENTOS

Agradeço à minha família especialmente meu pai por ter dedicado à vida a suas filhas para que tivessem uma boa educação. À minha irmã por ser minha melhor amiga desde sempre e companheira para tudo. À minha mãe Andrea por sempre se orgulhar de mim. Aos meus avós, Marlene e Josélino, e tios, Adriana e Jaime, por todo apoio e finais de semanas e churrascos em família dos quais eu sinto tanta falta.

Agradeço aos meus amigos pelas conversas, os ensinamentos e os momentos de lazer. Tenho um pedaço de vocês em mim.

Ao prof. Dr. Odemir Martinez Bruno, por todo incentivo, entusiasmo, orientação e paciência durante esses dois anos de mestrado. Aos colegas de laboratório por tornarem os dias mais leves, pelas trocas, conselhos e almoços no bandeirão.

Ao ICMC-USP, Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo, pela oportunidade e ao CNPq, Conselho Nacional de Desenvolvimento Científico e Tecnológico pela concessão da bolsa de mestrado.

“Eu sou invencível enquanto estiver vivo”
(John Mayer)

RESUMO

NEIVA, M. B.. **Métodos de pré-processamento de texturas para otimizar o reconhecimento de padrões.** 2016. 141 f. Dissertação (Mestrado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação (ICMC/USP), São Carlos – SP.

A textura de uma imagem apresenta informações importantes sobre as características de um objeto. Usar essa informação para reconhecimento de padrões vem sendo uma tarefa bastante pesquisada na área de processamento de imagens e aplicado em atividades como indústria têxtil, biologia, análise de imagens médicas, imagens de satélite, análise de peças industriais, entre outros. Muitos pesquisadores focam em criar mecanismos que convertam a imagem em um vetor de características a fim de utilizar um classificador sobre esse vetores. No entanto, as imagens podem ser transformadas para que que características peculiares sejam evidenciadas fazendo com que extratores de características já existentes explorem melhor as imagens. Esse trabalho tem como objetivo estudar a influência da aplicação de métodos de pré-processamento em imagens de textura para a posterior análise das imagens. Os métodos escolhidos são seis: difusão isotrópica, difusão anisotrópica clássica, dois métodos de regularização da difusão anisotrópica, um método de difusão morfológica e a transformada de distância. Além disso, os métodos foram aliados a sete descritores já conhecidos da literatura para que as características das imagens transformadas sejam extraídas. Resultados mostram um aumento significativo no desempenho dos classificadores KNN e Naive Bayes quando utilizados nas imagens transformadas de quatro bases de textura: Brodatz, Outex, Usptex e Vistex.

Palavras-chave: Textura, Pré-processamento de Imagens, Reconhecimento de Padrões, Difusão Anisotrópica, Difusão Morfológica, Difusão Isotrópica, Transformada da Distância.

ABSTRACT

NEIVA, M. B.. **Métodos de pré-processamento de texturas para otimizar o reconhecimento de padrões**. 2016. 141 f. Dissertação (Mestrado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação (ICMC/USP), São Carlos – SP.

The texture of an image plays an important source of information of the image content. The use of this information to pattern recognition became very popular in image processing area and has applications such in textile industry, biology, medical image analysis, satellite images analysis, industrial equipments analysis, among others. Many researchers focus on creating different methods to convert the input image to a feature vector to the able to classify the image based on these vectors. However, images can be modified in different ways such that important features are enhanced. Therefore, descriptors are able to extract features easily to perform a better representation of the image. This project aims to apply six different preprocessing methods to analyze their power of enhancement on the texture extraction. The methods are: isotropic diffusion, the classic anisotropic diffusion, two regularizations of the anisotropic diffusion, a morphologic diffusion and the distance transform. To extract the features of these modified images, seven texture analysis algorithms are used along KNN and Naive Bayes to classify the textures. Results show a significant increase when datasets Brodatz, Vistex, Usptex and Outex are transformed prior to texture analysis and classification.

Key-words: Texture, Image Preprocessing, Pattern Recognition, Anisotropic Diffusion, Morphologic Diffusion, Isotropic Diffusion, Distance Transform.

LISTA DE ILUSTRAÇÕES

Figura 1 – Um filtro de Gabor é formado por uma senóide convoluida com uma gaussiana no domínio do espaço.	39
Figura 2 – Banco de Filtros de Gabor (cinza = 0, branco = positivo, preto = valores negativos).	39
Figura 3 – Representação de um sistema multi-escala	51
Figura 4 – Imagem original e suavizadas com diferentes gaussianas, $\sigma = 2.0, 3.0$ respectivamente.	52
Figura 5 – Três imagens comparativas. A primeira mostra a imagem original. A segunda imagem é a o resultado da aplicação da difusão anisotrópica com $t = 10$, $\lambda = \frac{1}{4}$, $\kappa = 15$ e a g igual à Equação 4.10. A terceira mostra comparação com a difusão isotrópica, onde as regiões são 'diluidas' igualmente.	55
Figura 6 – Da esquerda pra a direita: imagem original, 10ª e 20ª iteração do algoritmo de regularização forward-backward da difusão anisotrópica.	56
Figura 7 – Diferentes iterações da difusão não local. Da primeira imagem original se derivam as duas outras imagens onde a segunda é referente a 10ª iteração e a terceira à 20ª iteração.	57
Figura 8 – Exemplo de imagem da base Usptex e a 1ª, 3ª e 5ª iteração do algoritmo de difusão anisotrópica morfológico respectivamente.	58
Figura 9 – Passo 1: Inicialmente a imagem em níveis de cinza é transformada em uma imagem binária 3D. Para cada posição (x,y,z) do voxel, esta recebe o valor de 1 se $I(x,y) = 1$ e 0 do contrário. Quando o voxel tem valor 1, a distância para o pixel de interesse é 0 (representado por quadrados pretos). Do contrário, tem valor ∞ . Depois a cada voxel de valor ∞ é calculado a distância quadrada mínima ao voxel 0 mais próximo na linha x.	60
Figura 10 – Passo 2: a imagem gerada no passo 1 (Figura 9) é novamente processada. Para cada pixel não 0 é calculado mínimo entre a soma de cada coluna e a distância ao quadrado do pixel em questão até a coluna a somada.	61
Figura 11 – Passo 3: O último passo é semelhante ao segundo. Porém a soma ocorre com os pixels na mesma linha e coluna mas diferente plano.	62
Figura 12 – Evolução das iterações (cortes no eixo z) da transformada da distância da primeira imagem. As imagens seguintes representam as iterações 20, 25 e 35 respectivamente.	62

Figura 13 – Diagrama do método proposto. Primeiro todas as imagens do banco são transformadas pelo método de pré-processamento (<i>pp</i>) gerando k novas imagens para cada imagem original. O segundo passo é analisar todas as imagens (originais e transformadas) com um descritor d . Cada vetor descrito da iteração i ($1 \leq i \leq k$) concatenado com o vetor de sua respectiva imagem original é utilizado pelo espaço do classificador para obter a taxa de acerto com uso de validação cruzada.	64
Figura 14 – Exemplos de imagens de diferentes classes encontradas no banco de dados Brodatz.	65
Figura 15 – Exemplos de imagens de diferentes classes encontradas no banco de dados Usptex.	66
Figura 16 – Exemplos de imagens de diferentes classes encontradas no banco de dados Outex.	66
Figura 17 – Exemplos de imagens de diferentes classes encontradas no banco de dados Vistex.	67
Figura 18 – Taxas de acerto obtidas pela utilização da gaussiana convoluida a imagem original. É mostrado a evolução para todos os descritores utilizando a base Vistex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	71
Figura 19 – Taxas de acerto obtidas pela utilização da gaussiana convoluida à imagem original. É mostrado a evolução para todos os descritores utilizando a base Brodatz e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	72
Figura 20 – Taxas de acerto obtidas pela utilização da gaussiana convoluida à imagem original. É mostrado a evolução para todos os descritores utilizando a base Outex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	73
Figura 21 – Taxas de acerto obtidas pela utilização da gaussiana convoluida à imagem original. É mostrado a evolução para todos os descritores utilizando a base Usptex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	74
Figura 22 – Taxas de acerto obtida pela utilização da difusão anisotrópica clássica aplicada nas imagens originais. É mostrado a evolução para todos os descritores utilizando a base Vistex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	78
Figura 23 – Taxas de acerto obtida pela utilização da difusão anisotrópica clássica aplicada nas imagens originais. É mostrado a evolução para todos os descritores utilizando a base Brodatz e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	79

Figura 24 – Taxas de acerto obtida pela utilização da difusão anisotrópica clássica aplicada nas imagens originais. É mostrado a evolução para todos os descritores utilizando a base Outex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	80
Figura 25 – Taxas de acerto obtida pela utilização da difusão anisotrópica clássica aplicada nas imagens originais. É mostrado a evolução para todos os descritores utilizando a base Usptex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	81
Figura 26 – Taxas de acerto obtidas pela utilização da regularização forward-backward da difusão anisotrópica nas imagens originais. É mostrado a evolução para todos os descritores utilizando a base Vistex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	84
Figura 27 – Taxas de acerto obtidas pela utilização da regularização forward-backward da difusão anisotrópica nas imagens originais. É mostrado a evolução para todos os descritores utilizando a base Brodatz e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	85
Figura 28 – Taxas de acerto obtidas pela utilização da regularização forward-backward da difusão anisotrópica nas imagens originais. É mostrado a evolução para todos os descritores utilizando a base Outex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	86
Figura 29 – Taxas de acerto obtidas pela utilização da regularização forward-backward da difusão anisotrópica nas imagens originais. É mostrado a evolução para todos os descritores utilizando a base Usptex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	87
Figura 30 – Taxas de acerto obtidas pela utilização da difusão anisotrópica não local aplicada as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Vistex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	90
Figura 31 – Taxas de acerto obtidas pela utilização da difusão anisotrópica não local aplicada as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Brodatz e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	91

Figura 32 – Taxas de acerto obtidas pela utilização da difusão anisotrópica não local aplicada as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Outex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	92
Figura 33 – Taxas de acerto obtidas pela utilização da difusão anisotrópica não local aplicada as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Usptex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	93
Figura 34 – Taxas de acerto obtida pela utilização do filtro de choque aplicados as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Vistex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	96
Figura 35 – Taxas de acerto obtida pela utilização do filtro de choque aplicados as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Brodatz e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	97
Figura 36 – Taxas de acerto obtida pela utilização do filtro de choque aplicados as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Outex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	98
Figura 37 – Taxas de acerto obtida pela utilização do filtro de choque aplicados as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Usptex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	99
Figura 38 – Taxas de acerto obtida pela utilização da EDT aplicadas as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Vistex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	103
Figura 39 – Taxas de acerto obtida pela utilização da EDT aplicadas as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Brodatz e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	104
Figura 40 – Taxas de acerto obtida pela utilização da EDT aplicadas as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Outex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	105

Figura 41 – Taxas de acerto obtida pela utilização da EDT aplicadas as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Usptex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.	106
Figura 42 – Comparação entre todos os resultados obtidos pelo classificador Naive Bayes para a base Brodatz.	110
Figura 43 – Comparação entre todos os resultados obtidos pelo classificador Naive Bayes para a base Outex.	111
Figura 44 – Comparação entre todos os resultados obtidos pelo classificador Naive Bayes para a base Vistex.	111
Figura 45 – Comparação entre todos os resultados obtidos pelo classificador Naive Bayes para a base Usptex.	112
Figura 46 – Comparação entre todos os resultados obtidos pelo classificador KNN (k = 1) para a base Brodatz.	112
Figura 47 – Comparação entre todos os resultados obtidos pelo classificador KNN (k = 1) para a base Outex.	113
Figura 48 – Comparação entre todos os resultados obtidos pelo classificador KNN (k = 1) para a base Vistex.	113
Figura 49 – Comparação entre todos os resultados obtidos pelo classificador KNN (k = 1) para a base Usptex.	114

LISTA DE TABELAS

Tabela 1	– Resultados da aplicação de gaussiana como método de pré-processamento com diferentes extratores e KNN ($k = 1$) como classificador.	75
Tabela 2	– Resultados da aplicação de gaussiana como método de pré-processamento com diferentes extratores e Naive Bayes como classificador.	76
Tabela 3	– Resultados obtidos com a aplicação do algoritmo de difusão anisotrópica clássico nas imagens originais das bases. O ganho é resultante da diferença entre o melhor resultado quando se aplica a difusão e o resultado em qualquer aplicação de pré-processamento na avaliação do KNN, $k = 1$	82
Tabela 4	– Resultados obtidos com a aplicação do algoritmo de difusão anisotrópica clássico nas imagens originais das bases. O ganho é resultante da diferença entre o melhor resultado quando se aplica a difusão e o resultado em qualquer aplicação de pré-processamento na avaliação do Naive Bayes	83
Tabela 5	– Resultados da aplicação da regularização forward-backward da difusão anisotrópica, são 150 iterações testas e a coluna melhor i apresenta a iteração que mostrou o melhor resultado. A tabela mostra os resultados para KNN, $k = 1$	88
Tabela 6	– Resultados da aplicação da regularização forward-backward da difusão anisotrópica, são 150 iterações testas e a coluna melhor i apresenta a iteração que mostrou o melhor resultado. A tabela mostra os resultados para Naive Bayes.	89
Tabela 7	– A tabela mostra os resultados da aplicação da difusão anisotrópica não local com os diferentes descritores e KNN, $k = 1$	94
Tabela 8	– A tabela mostra os resultados da aplicação da difusão anisotrópica não local com os diferentes descritores e Naive Bayes	95
Tabela 9	– Resultados da aplicação do filtro morfológico nas imagens dos quatro banco de dados com a análise de diferentes descritores e classificador KNN ($k = 1$).	100
Tabela 10	– Resultados da aplicação do filtro morfológico nas imagens dos quatro banco de dados com a análise de diferentes descritores e classificador Naive Bayes.	101
Tabela 11	– São apresentadas as taxas de sucesso com KNN, $k = 1$ a partir das imagens transformadas e não transformadas pelo método EDT.	107
Tabela 12	– São apresentadas as taxas de sucesso com Naive Bayes a partir das imagens transformadas e não transformadas pelo método EDT.	108
Tabela 13	– Resultados da aplicação de gaussiana como método de pré-processamento com diferentes extratores e KNN ($k = 3$) como classificador.	124

Tabela 14 – Resultados da aplicação de gaussiana como método de pré-processamento com diferentes extratores e KNN ($k = 5$) como classificador.	125
Tabela 15 – Resultados da aplicação de gaussiana como método de pré-processamento com diferentes extratores e KNN ($k = 7$) como classificador.	125
Tabela 16 – Resultados da aplicação de gaussiana como método de pré-processamento com diferentes extratores e KNN ($k = 9$) como classificador.	126
Tabela 17 – Resultados obtidos com a aplicação do algoritmo de difusão anisotrópica clássico nas imagens originais das bases. O ganho é resultante da diferença entre o melhor resultado quando se aplica a difusão e o resultado em qualquer aplicação de pré-processamento na avaliação do KNN, $k = 3$	127
Tabela 18 – Resultados obtidos com a aplicação do algoritmo de difusão anisotrópica clássico nas imagens originais das bases. O ganho é resultante da diferença entre o melhor resultado quando se aplica a difusão e o resultado em qualquer aplicação de pré-processamento na avaliação do KNN, $k = 5$	128
Tabela 19 – Resultados obtidos com a aplicação do algoritmo de difusão anisotrópica clássico nas imagens originais das bases. O ganho é resultante da diferença entre o melhor resultado quando se aplica a difusão e o resultado em qualquer aplicação de pré-processamento na avaliação do KNN, $k = 7$	128
Tabela 20 – Resultados obtidos com a aplicação do algoritmo de difusão anisotrópica clássico nas imagens originais das bases. O ganho é resultante da diferença entre o melhor resultado quando se aplica a difusão e o resultado em qualquer aplicação de pré-processamento na avaliação do KNN, $k = 9$	129
Tabela 21 – Resultados da aplicação da regularização forward-backward da difusão anisotrópica, são 150 iterações testas e a coluna melhor i apresenta a iteração que mostrou o melhor resultado. A tabela mostra os resultados para KNN, $k = 3$	130
Tabela 22 – Resultados da aplicação da regularização forward-backward da difusão anisotrópica, são 150 iterações testas e a coluna melhor i apresenta a iteração que mostrou o melhor resultado. A tabela mostra os resultados para KNN, $k = 5$	131
Tabela 23 – Resultados da aplicação da regularização forward-backward da difusão anisotrópica, são 150 iterações testas e a coluna melhor i apresenta a iteração que mostrou o melhor resultado. A tabela mostra os resultados para KNN, $k = 7$	131
Tabela 24 – Resultados da aplicação da regularização forward-backward da difusão anisotrópica, são 150 iterações testas e a coluna melhor i apresenta a iteração que mostrou o melhor resultado. A tabela mostra os resultados para KNN, $k = 9$	132
Tabela 25 – A tabela mostra os resultados da aplicação da difusão anisotrópica não local com os diferentes descritores e KNN, $k = 3$	133
Tabela 26 – A tabela mostra os resultados da aplicação da difusão anisotrópica não local com os diferentes descritores e KNN, $k = 5$	134

Tabela 27 – A tabela mostra os resultados da aplicação da difusão anisotrópica não local com os diferentes descritores e KNN, $k = 7$	134
Tabela 28 – A tabela mostra os resultados da aplicação da difusão anisotrópica não local com os diferentes descritores e KNN, $k = 9$	135
Tabela 29 – Resultados da aplicação do filtro morfológico nas imagens dos quatro banco de dados com a análise de diferentes descritores e classificador KNN ($k = 3$).	136
Tabela 30 – Resultados da aplicação do filtro morfológico nas imagens dos quatro banco de dados com a análise de diferentes descritores e classificador KNN ($k = 5$).	137
Tabela 31 – Resultados da aplicação do filtro morfológico nas imagens dos quatro banco de dados com a análise de diferentes descritores e classificador KNN ($k = 7$).	137
Tabela 32 – Resultados da aplicação do filtro morfológico nas imagens dos quatro banco de dados com a análise de diferentes descritores e classificador KNN ($k = 9$).	138
Tabela 33 – São apresentadas as taxas de sucesso com KNN, $k = 3$ a partir das imagens transformadas e não transformadas pelo método EDT.	139
Tabela 34 – São apresentadas as taxas de sucesso com KNN, $k = 5$ a partir das imagens transformadas e não transformadas pelo método EDT.	140
Tabela 35 – São apresentadas as taxas de sucesso com KNN, $k = 7$ a partir das imagens transformadas e não transformadas pelo método EDT.	140
Tabela 36 – São apresentadas as taxas de sucesso com KNN, $k = 9$ a partir das imagens transformadas e não transformadas pelo método EDT.	141

LISTA DE ABREVIATURAS E SIGLAS

EDT		Transformada de Distância Euclidiana
FBR		Regularização Forward-backward da Difusão Anisotrópica
G		Difusão Linear
GLCM	...	Matriz de co-ocorrência de níveis de cinza
GLDM	...	Matriz de diferenças de níveis de cinza
KNN		k- Vizinhos Mais Próximos
LBP		Padrão Binário Local
NL		Difusão Anisotrópica Não Local
PM		Difusão Anisotrópica Clássica
SF		Difusão Morfológica
SVM		Máquina de Vetores de Suporte

SUMÁRIO

1	INTRODUÇÃO	29
1.1	Justificativa e Motivação	29
1.2	Objetivos	30
1.3	Organização	31
2	ANÁLISE DE TEXTURA	33
2.1	Análise Estrutural da Textura	34
2.2	Análise Estatística da Textura	34
2.2.1	<i>Características de Primeira Ordem</i>	35
2.2.2	<i>Matriz de Co-ocorrência</i>	36
2.2.3	<i>GLDM - Método de Diferenças de Tons de Cinza</i>	37
2.2.4	<i>Local Binary Pattern</i>	38
2.3	Análise Espectral da Textura	38
2.3.1	<i>Extrator de Gabor</i>	39
2.3.2	<i>Descritores de Fourier</i>	40
2.4	Análise Baseada em Modelos	41
2.4.1	<i>Descritores Fractais</i>	41
3	RECONHECIMENTO DE PADRÕES	43
3.1	K - Vizinhos Mais Próximos	43
3.2	<i>Naïve Bayes</i>	44
3.3	Máquinas de Vetores de Suporte	45
3.4	Validação Cruzada	46
4	MÉTODOS DE PRÉ PROCESSAMENTO	49
4.1	Análise Multiescala	50
4.2	Abordagem linear	51
4.3	Abordagens não-linear	52
4.3.1	<i>Difusão Anisotrópica por Perona-Malik</i>	52
4.3.2	<i>Regularização Forward-Backward da Difusão Anisotrópica</i>	54
4.3.3	<i>Difusão Anisotrópica Não Local</i>	55
4.4	Abordagem Morfológica	56
4.5	Transformada de Distância Euclidiana	58

5	METODOLOGIA	63
5.1	Bases de Dados Utilizadas	65
5.1.1	<i>Brodatz</i>	65
5.1.2	<i>Usptex</i>	65
5.1.3	<i>Outex</i>	65
5.1.4	<i>Vistex</i>	66
5.2	Configuração dos Métodos	66
5.2.1	<i>Métodos de Extração de Características</i>	67
5.2.2	<i>Métodos de Classificação</i>	68
6	RESULTADOS	69
6.1	Difusão Linear	69
6.2	Difusão Anisotrópica por Perona-Malik	75
6.3	Regularização Forward-Backward da Difusão Anisotrópica	82
6.4	Difusão Anisotrópica Não Local	88
6.5	Espaço de Escala gerado por Morfologia Matemática	94
6.6	Transformada de Distância Euclidiana	100
6.7	Discussão dos Resultados	107
7	CONCLUSÕES	115
	REFERÊNCIAS	117
APÊNDICE A	RESULTADOS COM KNN	123
A.1	Difusão Linear	124
A.2	Difusão Anisotrópica por Perona-Malik	127
A.3	Regularização Forward-Backward da Difusão Anisotrópica	130
A.4	Difusão Anisotrópica Não Local	133
A.5	Espaço de Escala gerado por Morfologia Matemática	136
A.6	Transformada de Distância Euclidiana	139

INTRODUÇÃO

1.1 Justificativa e Motivação

Ao longo dos anos, pesquisadores da área de Visão Computacional vêm descobrindo o poder da análise de textura para o reconhecimento de padrões em tarefas como biologia (BACKES; BRUNO, 2009), inspeção de peças industriais (XIE; MIRMEHDI, 2007), imagens médicas (GLATARD; MONTAGNAT; MAGNIN, 2004) imagens de satélite (ZHAO; ZHANG; LI, 2005), análise de peças industriais (XIANGHUA; MIRMEHDI, 2007), entre outros.

Textura, mais que forma ou cor, apresenta características importantes dos objetos e podem representá-los de maneira mais precisa. Ela está associada à distribuição dos pixels em uma imagem, tanto em relação à intensidade quanto a posição. Definir o que é textura não é uma tarefa fácil. Muitos a definem como um padrão repetitivo, porém a falta de padrão pode caracterizar uma imagem como no caso dos ruídos. O importante é o fato de que é possível representar uma imagem pela sua textura visual a fim de:

- Extrair características: por meio de vetores numéricos;
- Segmentar imagens: em regiões de características semelhantes;
- Classificar texturas: agrupando diferentes imagens de texturas em suas respectivas classes;
e
- Reconstruir texturas: a partir de informações limitadas sobre estas.

Extrair características é base para as três outras tarefas, a fim de compreender melhor cada uma de suas peculiaridades e analisá-las de uma maneira mais enxuta, por meio de vetores. Porém, extrair características não é uma tarefa simples. Bases de dados de imagens reais são tomadas por diferenças em iluminação, posição, ruídos, entre fatores outros que tornam a

eficiente extração de características um trabalho árduo. Muitos trabalhos se atentam em criar diferentes estratégias para a tarefa utilizando a taxa acerto no reconhecimento de padrões como avaliador dos seus novos métodos descritores (FLORINDO; BRUNO, 2013; GALLOWAY, 1975; ZÚÑIGA; FLORINDO; BRUNO, 2014). No entanto, poucos se preocupam em tratar a imagem da textura antes de aplicar estes extratores de características, transformando-as e consequentemente, evidenciando características importantes da textura.

As abordagens que modificam a imagem original utilizam-se de métodos como equalização de histogramas, binarização e operações morfológicas (ANITHA; RADHA, 2010). Em aplicações como análise de produtos defeituosos como na indústria têxtil, é importante que estes não cheguem até o consumidor e por questões de diferenças de iluminação e ruídos nas imagens é importante que elas sejam pré-processadas. A taxa de erro na detecção deve ser reduzida ao se aplicar esses métodos.

Em outro artigo, GLATARD; MONTAGNAT; MAGNIN (2004) utilizam uma pirâmide de filtros como Laplaciano e equalização de histogramas para segmentar imagens de ressonância magnética utilizando uma posterior análise de textura para a segmentação das imagens. Apesar da falta de modelos para comparação dos resultados, a aplicação dos métodos de pré-processamento auxiliou na melhor segmentação das deformações de imagens de ressonância.

1.2 Objetivos

Utilizar métodos antes da análise de textura pode trazer vantagens enaltecendo as características das imagens e principalmente evidenciando atributos intra-classe das texturas. Embora diversos métodos possam ser aplicados para transformar imagens e explorados no pré-processamento de texturas, neste trabalho foram abordadas seis técnicas: transformada da distância, quatro métodos de difusão anisotrópica e a difusão isotrópica.

Visto que a análise multi-escala evidencia diferentes aspectos da imagem de acordo com a escala avaliada, diferentes métodos de difusão foram estudados neste trabalho. O primeiro e mais simples na análise multi-escala é a aplicação de uma Gaussiana. Nesse formato, a suavização é igual em todos os pontos da imagem não obedecendo limites de bordas. Já nos métodos de difusão anisotrópica, a imagem é suavizada com certo controle. A região na qual está sendo aplicada a difusão é analisada para que a proporção correta de difusão seja aplicada. É dado privilégio a suavização intra-região em comparação com áreas entre regiões. Quatro diferentes maneiras de se aplicar a difusão anisotrópica serão estudadas nesse trabalho.

O último método, a transformada de distância, tem como objetivo calcular a distância de cada pixel do fundo para o pixel do objeto mais próximo. A transformada funciona como uma dilatação da imagem de textura, sendo possível analisar os detalhes em cada nível de dilatação gerado. Apesar de não estar estritamente ligado a multi-escala, na transformada de distância a dilatação faz com que algumas formas desapareçam mais rapidamente deixando bordas em

evidência em 'escalas' mais altas.

Este trabalho tem como objetivo aplicar os métodos de pré-processamento nas imagens originais e então aplicar métodos já existentes de análise de textura como LBP (*Local Binary Patterns*), filtros de Gabor, características de Fourier, entre outros nas imagens transformadas para a partir da taxa de acerto obtido no reconhecimento de padrões em texturas, analisar a influência dos métodos de pré-processamento nos descritores.

Experimentos mostram um aumento significativo na taxa de acerto quando esses métodos são utilizados. Para todas as bases estudadas (Brodatz, Usptex, Vistex e Outex), os descritores GLDM, Gabor e Fractal foram beneficiados pelo uso dos métodos multi-escala. Dentre eles, o algoritmo de análise de textura GLDM foi o mais auxiliado com o uso dos métodos enquanto os algoritmos de análise de histograma e GLCM não foram melhorados quando os métodos de difusão anisotrópica são utilizados.

1.3 Organização

O texto foi organizado da seguinte maneira: o Capítulo 2 explica os principais métodos de extração de características de textura conhecidos na literatura, além de apresentar as principais aplicações de sua utilização. Todos os métodos apresentados foram utilizados para análise da proposta. O Capítulo 3 apresenta os métodos de reconhecimento de padrões mais utilizados. Dois deles foram utilizados para avaliação e comparação dos resultados com e sem pré-processamento. As descrições dos métodos de pré-processamento são encontradas no Capítulo 4. No capítulo de metodologia são explicados os experimentos, as bases e todos os parâmetros utilizados tanto para os algoritmos de análise quanto para os de classificação. Os parâmetros dos métodos de pré-processamento e os seus resultados e observações são mostrados no Capítulo 6. Finalmente, o último capítulo apresenta a conclusão do trabalho com o resumo do projeto e análise dos melhores resultados.

ANÁLISE DE TEXTURA

Existem diferentes maneiras para extrair características de uma imagem. No entanto, uma estratégia que tem se mostrado muito acertiva é o uso da informação de textura. Em muitas aplicações a análise da cor e formato pode não ser suficiente para reconhecer um objeto. Por isso, uma outra metodologia de análise de imagem é a utilização de extração de característica a partir da informações de textura da cena. Definir o que é textura parece não ser um consenso entre os estudiosos ([GONZALEZ, 2009](#)). O único consenso é que uma textura é relacionada a uma janela da imagem, ou seja, dependente da escala ([RUSS; WOODS, 1995](#)). No entanto, apesar da falta de definição, parece fácil para seres humanos entenderem a textura e o quão importante ela é para o reconhecimento de um objeto. Deste modo, sistemas de visão computacional tentam extrair características baseado na organização dos pixels na imagem. Essa organização pode refletir propriedades importantes do objeto como aspereza, luminosidade, uniformidade, densidade, entre outros. Quatro tipos aplicações podem ser beneficiadas com o estudo de análise de textura em imagens:

- Síntese de Textura: quando há uma porção limitada da textura e é necessário estendê-la de maneira natural. Muito utilizada em áreas de computação gráfica, jogos e filmes.
- Reconhecimento de Objetos: características de textura podem ser (ou não) combinadas com características de cor e forma para reconhecer objetos como em taxonomia vegetal ([BACKES; BRUNO, 2009](#))
- Análise de objetos em indústrias: como um segmento prático muito importante, a análise de superfície de objetos é essencial na indústria para verificação de produtos com defeitos para que não cheguem ao consumidor final.
- Segmentação de objetos: encontrar diferentes tipos de texturas em uma única imagem é importante para tarefas como análise de imagens de satélite ([ZHAO; ZHANG; LI, 2005](#)), entre outras.

Criar um algoritmo de reconhecimento de texturas que funcione tão bem quanto o reconhecimento feito pelo cérebro humano é uma tarefa muito difícil. Bases de dados de textura reais apresentam diferenças na iluminação, posição, entre outros fatores que dificultam que a extração de características de uma mesma textura seja preciso. Por isso, muitos descritores foram surgindo ao longo dos anos e podem ser separados em diferentes categorias apresentadas nas próximas seções.

2.1 Análise Estrutural da Textura

Muitos autores se baseiam em abordagens estruturais para caracterizar texturas. Nessa categoria, é assumida que texturas são formadas por primitivas posicionadas na imagem de acordo com uma regra. Como existem texturas estocásticas e regulares, esse tipo de abordagem tende a funcionar melhor em texturas regulares onde as regras de posicionamento dessas primitivas, mais fáceis de reconhecer, são simples. Para modelar um algoritmo de análise estrutural, dois passos são necessários: (1) encontrar as estruturas primitivas e (2) encontrar a regra de posicionamento. As estruturas são geralmente dadas por regiões de alto gradiente e podem ser representadas por bordas, polígonos de Voronoi (TÜCERYAN; JAIN, 1990) e formas. Em MATSUYAMA; MIURA; NAGAO, 1983 a regra é obtida a partir de picos na transformada de Fourier da imagem de textura. Já ZUCKER (ZUCKER, 1976) propõe um método que caracteriza texturas reais a partir de distorções de texturas ideais.

Este tipo de estratégia não será tão explorado nesta dissertação, pois possui um número limitado de aplicações tendo em vista que a maioria das texturas encontradas não são regulares. Uma utilização da estratégia é encontrada na análise microestruturas ósseas em MATERKA; STRZELECKI *et al.*, 1998.

2.2 Análise Estatística da Textura

Imagens de textura em escala de cinza são representados por uma matriz $m \times n$ onde cada posição contém a intensidade do ponto. A abordagem de modelagem estatística utiliza a informação de distribuição desses pixels na imagem para construir suas características. Um dos métodos mais famosos nessa categoria são o GLCM, *Gray Level Co-Occurrence Matrix*, baseado no uso de estatísticas de segunda ordem e uma evolução dele, o GLDM, *Gray Level Difference Matrix* que serão explicados com mais detalhes e utilizados no trabalho em questão.

Métodos baseados em estatísticas de segunda ordem têm como vantagem olhar a relação espacial entre pixels a uma determinada posição relativa no espaço ao contrário dos métodos que avaliam apenas pixels individualmente. Segundo JULESZ (JULESZ, 1975), texturas são mais facilmente diferenciadas quando seus momentos de segunda ordem são bem distintos. Para testes com duas texturas com os valores de momento de segunda ordem iguais, mas diferentes

momentos de terceira ordem, o reconhecimento humano que as duas texturas eram diferentes foi prejudicado. Além disso, outro método utilizado no trabalho é a análise do histograma, que extrai características da imagem baseado em estatísticas retiradas de seu histograma.

2.2.1 Características de Primeira Ordem

Uma imagem f de níveis de intensidade variando 1 a L e tamanho $m \times n$ gera um histograma de acordo com a seguinte fórmula:

$$h(i) = \sum_{x=1}^m \sum_{y=1}^n \text{bool}(f(x,y), i), \text{ para } 1 \leq i \leq L \quad (2.1)$$

sendo,

$$\text{bool}(f(x,y), i) = \begin{cases} 1, & \text{se } f(x,y) = i \\ 0, & \text{do contrário} \end{cases} \quad (2.2)$$

O histograma nada mais é do que o cálculo das frequências de cada uma das intensidades na imagem. O formato do histograma provê informações de brilho da imagem, histogramas com valores mais altos no início, indicam imagens mais escuras. Como indicativos quantitativos, estatísticas como média (Equação 2.3), desvio padrão (Equação 2.4), entre outros (Equações de 2.6 à 2.9) são usualmente calculadas e utilizadas como características da textura (MALIK; BAHARUDIN, 2013). Nas equações abaixo, M é relacionado ao tamanho da imagem e

Média:

$$\mu = \sum_{i=1}^L \frac{h(i)i}{M} \quad (2.3)$$

Desvio Padrão:

$$\sigma = \sqrt{\sum_{i=1}^L (i - \mu)^2 (h(i)/M)} \quad (2.4)$$

Assimetria:

$$\frac{1}{\sigma^3} \sum_{i=1}^L (i - \mu)^3 (h(i)/M) \quad (2.5)$$

Curtose:

$$\frac{1}{\sigma^4} \sum_{i=1}^L (i - \mu)^4 (h(i)/M) - 3 \quad (2.6)$$

Energia:

$$\sum_{i=1}^L [(h(i)/M)] \quad (2.7)$$

Entropia:

$$-\sum_{i=1}^L (h(i)/M) \log_2 [h(i)/M] \quad (2.8)$$

Suavidade:

$$1 - \frac{1}{1 + (\sigma)^2} \quad (2.9)$$

Além dos citados acima, também pode ser utilizado informações como valor máximo, mínimo e mediana. Pode-se utilizar mais de um quantizador para representar a imagem. O uso da média nos dá a informação da intensidade média da textura enquanto a variância mostra o quanto as intensidades variam ao redor dessa média. A assimetria tem o valor de 0 quando o histograma é simétrico para os dois lados em relação à média. Por fim, a curtose mede o quão constante é o histograma. Para um histograma com formato de gaussiana, o valor de curtose é 0.

Quando esse tipo de estatística é utilizada bases de dados com variações de iluminação intra-classe não são bem representadas. São analisadas as intensidades isoladamente e não a relação entre elas na imagem. Uma mudança no valor dos pixels altera valores de média que se comparados pode gerar confusão mesmo pertencendo à mesma classe de texturas. Para amenizar o efeito de mudanças de iluminação, uma alternativa é normalizar a imagem.

2.2.2 Matriz de Co-ocorrência

O segundo método estatístico é o de matrizes de co-ocorrência que utiliza a relação entre pixels vizinhos para caracterizar a textura. Como dito anteriormente, [JULESZ \(JULESZ, 1975\)](#) constatou que texturas diferentes mas muito parecidas são melhores diferenciadas quando tem seus momentos de segunda ordem diferentes.

Para o cálculo é gerado a matriz de co-ocorrência (GLCM), no qual é computado para cada par de intensidade de pixels i, j a quantidade de vezes que eles aparecem na imagem considerando uma distância d e um ângulo θ (convertidos em $\Delta x, \Delta y$). A partir da matriz é possível calcular a probabilidade conjunta $p(i, j)$ de dois pixels a certa distância de possuírem valores i e j . A Equação abaixo expressa o cálculo de uma matriz de co-ocorrência.

$$\text{GLCM}_{\Delta x, \Delta y}(i, j) = \sum_{p=1}^M \sum_{q=1}^N \begin{cases} 1, & \text{se } I(p, q) = i \text{ e } I(p + \Delta x, p + \Delta y) = j \\ 0, & \text{do contrário} \end{cases} \quad (2.10)$$

Para o vetor de características, medidas são extraídas da matriz como:

Contraste:

$$\sum_{i=1}^L \sum_{j=1}^L (i - j)^2 p(i, j) \quad (2.11)$$

Segundo momento angular (energia):

$$\sum_{i=1}^L \sum_{j=1}^L p(i, j)^2 \quad (2.12)$$

Entropia:

$$-\sum_{i=1}^L \sum_{j=1}^L p(i, j) \log_2 p(i, j) \quad (2.13)$$

Correlação:

$$\sum_{i=1}^L \sum_{j=1}^L [ijp(i, j) - \mu_x \mu_y] / (\sigma_x \sigma_y) \quad (2.14)$$

Valor Absoluto:

$$\sum_{i=1}^L \sum_{j=1}^L |i - j| p(i, j) \quad (2.15)$$

Diferença Inversa:

$$\sum_{i=1}^L \sum_{j=1}^L \frac{p(i, j)}{1 + (i - j)^2} \quad (2.16)$$

Probabilidade Máxima:

$$\max_{i, j} p(i, j) \quad (2.17)$$

A matriz GLCM possui L^2 elementos, sendo L a intensidade máxima da imagem. Para reduzir o custo computacional, alguns trabalhos reduzem a quantidade de níveis de cinza da imagem (HARALICK, 1979).

2.2.3 GLDM - Método de Diferenças de Tons de Cinza

Diferente do GLCM, mas também utilizando a relação entre os pixels para gerar características, o método GLDM calcula, a partir da imagem $f(x, y)$, uma nova imagem de diferenças $f_\delta(x, y) = |f(x, y) - f(x + \Delta x, y + \Delta y)|$, sendo $\delta = (\Delta x, \Delta y)$ são parâmetros do método. A partir dessa nova imagem, a função de densidade p_δ é calculada e várias medidas são obtidas:

Contraste:

$$\sum i^2 p_\delta(i) \quad (2.18)$$

Segundo momento angular:

$$\sum p_\delta(i)^2 \quad (2.19)$$

Entropia:

$$-\sum p_\delta(i) \log p_\delta(i) \quad (2.20)$$

Média:

$$(1/M) \sum i p_\delta(i) \quad (2.21)$$

Por fim, as métricas acima são concatenadas e utilizadas como vetor de características da imagem de entrada.

2.2.4 Local Binary Pattern

O LBP (Padrão Binário Local) (OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002) é um exemplo de descritor estatístico calculado com base no pixel central de um círculo e os pixels a sua volta. O pixel central (intensidade g_c) é utilizado como limiar para os pixels da circunferência (intensidade g_p , $1 \leq p \leq P$) (Equação 2.22) que gera um vetor binário. A transformação desse valor binário b para um número decimal k gera uma contagem para o valor k no histograma (Equação 2.23). O algoritmo funciona como um laço onde a cada iteração um pixel é utilizado como pixel central e portanto um número é formado. Ao final do algoritmo cria-se um histograma dos valores binários (convertidos para decimal) e este histograma é usado como vetor de característica da imagem.

Pode-se escolher no algoritmo o tamanho do círculo a ser utilizado para composição do número binário, i.e. o valor máximo P de vizinhos e o raio r . Se uma janela de 3x3 for escolhida, haverá $P = 8$ pixels a ser utilizados para formar o número binário. O histograma, e consequentemente o vetor de características, terá $2^8 = 256$ posições.

$$LBP_{P,r} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p, s(x) = \begin{cases} 1, x \geq 0 \\ 0, x < 0 \end{cases} \quad (2.22)$$

$$H(k) = \sum_{i=1}^M \sum_{j=1}^N \text{bool}(LBP_{P,r}(i, j), k),$$

$$\text{sendo } k \in [0, K]$$

(2.23)

$$\text{bool}(x, y) = \begin{cases} 1, x = y \\ 0, \text{do contrário} \end{cases}$$

2.3 Análise Espectral da Textura

Na abordagem espectral, as imagens têm seu domínio transformado de espacial para espectral. Nesses métodos, características são extraídas das imagens a partir de respostas a filtros. Dentre os métodos mais conhecidos estão o de Fourier e Gabor. Na análise por Fourier é perdido a informação espacial da imagem, pois na maioria das vezes a informação de fase não é utilizada. No entanto, quando se analisa a textura por respostas de filtros de Gabor esse problema é solucionado. Estes dois métodos serão apresentados nesta seção e utilizados no trabalho.

2.3.1 Extrator de Gabor

Filtros de Gabor são formados por um sinal senoidal modulado por uma Gaussiana (Figura 1). Um filtro de Gabor circular é dado pela seguinte função (KONG; ZHANG; LI, 2003):

$$G(x, y, \theta, u, \sigma) = \frac{1}{2\pi\sigma^2} \exp\left\{-\frac{x^2 + y^2}{2\sigma^2}\right\} \exp\{2\pi i(ux\cos\theta + uysin\theta)\} \quad (2.24)$$

, sendo $i = \sqrt{-1}$, u é a frequência da onda senoidal, θ controla a orientação da função e σ é o desvio padrão da gaussiana. A Figura 2 apresenta um exemplo com 25 filtros de Gabor, cada um dos filtros evidencia uma característica específica da imagem.

Figura 1 – Um filtro de Gabor é formado por uma senóide convolvida com uma gaussiana no domínio do espaço.

Fonte: Elaborada pelo autor.

Figura 2 – Banco de Filtros de Gabor (cinza = 0, branco = positivo, preto = valores negativos).

Fonte: Idrissa e Acheroy (2002).

O filtro de Gabor tem como vantagem a análise da imagem tanto no espaço quanto na frequência. Para a extração de características, cada filtro $g_{\sigma,\theta}(x,y)$ é convoluído à imagem gerando uma saída $c_{\sigma,\theta}(x,y)$.

O vetor de características $v = [E_{11}, E_{12}, \dots, E_{\sigma_{max}\theta_{max}}]$ pode ser gerado calculando a energia de cada uma das imagens c de acordo com a seguinte equação:

$$E_{\sigma,\theta} = \sum_{x,y} [c_{\sigma,\theta}(x,y)]^2 \quad (2.25)$$

2.3.2 Descritores de Fourier

A transformada de Fourier (HSU, 1973) é muito utilizada em tarefas de processamento de imagem principalmente para remoção de ruídos e desfoque de imagens. Inicialmente proposto por (COSGRIFF, 1960), os descritores de Fourier são utilizados para descrever um sinal a partir de sua transformada de Fourier. Proposto por FOURIER, a transformada consiste na transformação de um sinal periódico em uma soma de senos e/ou cossenos de frequências e amplitudes diferentes. A transformada de uma função bidimensional f é dada pela seguinte equação:

$$F(u, v) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) e^{-2j\pi(ux+vy)} dx dy. \quad (2.26)$$

Para imagens, pode-se calcular a transformada de acordo com a Função abaixo (onde $M \times N$ é referente ao tamanho da imagem):

$$F(u, v) = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) e^{-j2\pi(ux/M+vy/N)} \quad (2.27)$$

Uma maneira muito comum de extrair característica via espectro de Fourier é aplicar a transformada à textura ($f(x, y)$) multiplicada por $(-1)^{(x+y)}$, para que a frequência $u = 0$ e $y = 0$ se encontre no centro da transformada:

$$\mathcal{F}[f(x, y)(-1)^{x+y}] = F(u - M/2, v - N/2). \quad (2.28)$$

para compreender o significado da transformada, a posição $F(0,0)$ da matriz (isso quando se utiliza a Equação 2.28) contém a média dos pixels da imagem. Os coeficientes de baixo índice, i.e. baixa frequência, representam as regiões mais homogêneas. Do contrário, coeficientes de frequência alta, representam regiões de mudanças bruscas como bordas e quinas.

Existem dois tipos de características a ser extraídas da imagem. A primeira é em relação a setores de anéis circulares (E_a) e a segunda em relação a regiões circulares (E_b). O vetor final de características é formado pela concatenação de todos os $E_{a_{ij}}$ e E_{b_i} .

$$E_{a_{ij}} = \int_0^{\lambda_i} \int_{\theta_j}^{\theta_{j+1}} |F(\lambda, \theta)|^2 d\theta d\lambda \quad (2.29)$$

$$E_{b_i} = \int_0^{\lambda_i} \int_0^{2\pi} |F(\lambda, \theta)|^2 d\theta d\lambda, \quad (2.30)$$

sendo λ e θ as coordenadas polares no domínio da frequência. Os conjuntos $\{\lambda_i\}_{i=1}^r$ e $\{\theta_j\}_{j=1}^N$ são os parâmetros com r raios e N orientações.

2.4 Análise Baseada em Modelos

2.4.1 Descritores Fractais

A geometria mais comumente utilizada é a euclidiana. Nela, pontos tem dimensão zero, retas possuem dimensão 1 e assim por diante. No entanto, até a década de 70, não havia uma maneira de explicar a dimensão de objetos infinitos como a estrela de Koch, uma forma iniciada como um triângulo equilátero onde cada segmento do triângulo é transformado em três novos segmentos de comprimento igual por tempo infinito (COSTA; JR, 2000).

Dessa maneira, dado o problema de definir a dimensão para objetos complexos, a geometria fractal foi criada. Diferente da geometria euclidiana, em que as dimensões são representados por números inteiros, nos fractais, a dimensão é fracionária (NEIL; CURTIS, 1997).

Inicialmente criada para representar objetos complexos, a geometria fractal pode ser utilizada para entender o comportamento de texturas. Isso vem do fato que a geometria fractal é muito utilizada para estudar fenômenos naturais, assim como a natureza de muitas texturas, apresentando uma estrutura não periódica (KAPLAN, 1999).

Portanto, uma maneira de descrever texturas é estimar sua dimensão fractal. Para isso, vários métodos foram propostos desde a década de 70. Um dos mais famosos e preciso é o método de Bouligand-Minkoswi (TRICOT, 1994). Pode se dizer, que a dimensão fractal está relacionada com a complexidade do objeto, portanto, o método de Bouligand-Minkoswi é baseado no cálculo da área de influência do objeto quando dilatado por um disco de raio r .

Para estimar a dimensão é calculado o coeficiente angular da reta $\log A(r) \times \log(r)$, onde $A(r)$ é a estimativa da área de influência em relação a um raio r . Vários raios são analisados para obter a reta e a dimensão é dada pela seguinte equação:

$$dim = 2 - \lim_{\epsilon \rightarrow 0} \frac{\log A(r)}{\log(r)} \quad (2.31)$$

A área de influência é totalmente dependente do formato da imagem, qualquer pequena deformação no objeto é avaliado pela dilatação. A Equação 2.31 calcula dimensão fractal para imagens binárias. No caso de texturas, temos imagens em escala de cinza e por isso há a necessidade da dimensão fractal volumétrica, onde a área é substituída pelo cálculo do volume e o disco é substituído por uma esfera:

$$dim = 3 - \lim_{r \rightarrow 0} \frac{\log V(r)}{\log(r)} \quad (2.32)$$

Para descrever a textura pode-se utilizar a dimensão fractal da imagem. Porém, um valor talvez não seja suficiente para representar a complexidade da imagem. Duas imagens completamente distintas podem possuir dimensão fractal muito similar. Por esse motivo, uma

ideia é utilizar o próprio gráfico $\log V(r) \times \log(r)$ como vetor de características. O vetor de características do fractal utilizado neste trabalho é dado pela equação:

$$V = [V(r_1), V(r_2), \dots, V(r_m)], \quad (2.33)$$

sendo r_m é o raio da esfera utilizado para o cálculo do volume V . Na prática, para raios grandes, o volume dá a idéia do formato geral do objeto, enquanto para raios pequenos, é representado a complexidade de microestruturas da superfície. Por isso, a concatenação dos volumes como vetor de características é necessária para dar uma ideia mais completa sobre a textura analisada.

RECONHECIMENTO DE PADRÕES

Para avaliar a influência dos métodos de pré-processamento aplicados antes da extração de características será analisada a taxa de reconhecimento das texturas utilizadas nos experimentos. Este capítulo detalha métodos de classificação de padrões mais frequentes na literatura. São eles: K-Vizinhos Mais Próximos, *Naive Bayes* e Máquinas de Vetores de Suporte, o SVM.

3.1 K - Vizinhos Mais Próximos

Dado um conjunto de dados já rotulados e dados não classificados, o método é capaz de atribuir rótulos aos exemplos não conhecidos de acordo com sua distância aos já rotulados. O método, bastante simples, além de classificar os novos elementos também é capaz de mostrar como eles estão dispostos no espaço de dados.

Neste método, não há necessidade de fase de pré-treino, todo o processamento é feito na hora da classificação. O algoritmo possui um parâmetro k , e a partir deste, atribui ao novo exemplo, a classe majoritária entre seus k vizinhos mais próximos no espaço.

Para o cálculo dos vizinhos mais próximos é utilizada uma métrica de distância como mahalanobis, hamming e minkowsky. No entanto, a mais utilizada é a distância euclidiana. A equação abaixo apresenta o cálculo da distância entre dois vetores x e y com n atributos:

$$d(x, y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2} \quad (3.1)$$

O número de vizinhos a ser analisados é um valor atribuído pelo usuário. Se o valor de k for muito pequeno, ruídos podem afetar a classificação do novo exemplo. No entanto, se o valor de k for muito alto, a classe atribuída ao novo ponto pode não ser representativa.

A implementação do algoritmo é simples por ser um cálculo de distância e ordenação destas para encontrar os vizinhos mais próximos. No entanto, o tempo de processamento é

altamente dependente da quantidade de atributos dos vetores e quantidades de exemplos já classificados no espaço. Como referido anteriormente, não há fase de pré-treino, portanto, quando um novo exemplo é adicionado na base rotulada, não há necessidade de atualizar o classificador.

3.2 Naive Bayes

O segundo método utilizado é o *Naive Bayes*. Baseado na teoria de Bayes, esse classificador é dito ingênuo (do inglês *naive*) por supor que os atributos de um vetor são independentes. Apesar de essa suposição estar incorreta em muitos exemplos de aplicações o algoritmo apresenta bons resultados de classificação e por isso é muito utilizado na literatura.

Supondo atributos independentes, a probabilidade de um conjunto $A_i, \dots, A_n$ ocorrer dado que B ocorreu pode ser calculada de acordo com a seguinte equação:

$$P(A_i, \dots, A_n | B) = \prod_i P(A_i | B) \quad (3.2)$$

Dado um vetor de atributos que representam certo exemplo e , o programa calcula a probabilidade do exemplo e pertencer a classe c , ou seja, encontra a probabilidade $P(c | e)$. Para isso é estimada a probabilidade à priori $P(c)$ e as probabilidades $P(e_i | c)$, i.e., a probabilidade de cada atributo i do vetor e pertencer a classe c .

Para a atribuição da classe, o algoritmo encontra aquela que possui a maior probabilidade do exemplo pertencer:

$$classe_e = \operatorname{argmax}_{c \in C} P(c | e) = \operatorname{argmax}_{c \in C} P(c) \prod_{i=1}^n P(e_i | c). \quad (3.3)$$

Na prática, o produtório é substituído por um somatório do log das probabilidades para evitar *underflow*.

O método supõe que todos os atributos possuem a mesma importância e como mencionado anteriormente, que eles não possuam relação entre si. Isso porque o cálculo de $P(c | e)$ é dado por $\frac{P(e|c)P(c)}{P(e)}$ e pode ser substituído pelo produtório somente se os atributos de e são independentes.

Um exemplo em que é muito utilizado o algoritmo é na classificação de textos. Para isso dado um novo documento d e a probabilidade de cada classe já calculada pelo conjunto de treinamento $P(c_j)$, é calculada a probabilidade a priori de cada palavra do texto d aparecer em textos da classe c_j . Essas probabilidades são multiplicadas e tem-se a probabilidade $P(c_j | d)$. A probabilidade $P(c_j)$ é calculada para todas as classes do conjunto de treino, e é atribuído ao novo texto d aquela que retornou o maior valor.

3.3 Máquinas de Vetores de Suporte

Máquinas de Vetores de Suporte, ou *Support Vector Machines (SVM)* em inglês, é um método de classificação de padrões muito conhecido entre os cientistas da computação e dado por muitos como o melhor classificador conhecido. Segundo (SMOLA *et al.*, 2000) as principais características do SVM são: boa capacidade de classificar padrões ainda não conhecidos, robustez em grandes dimensões, convexidade da função objetivo (função de minimização possui apenas um mínimo global) e teoria bem definida (baseado na teoria de aprendizado estatístico).

O modelo básico do SVM é utilizado para classificar novos exemplos em uma das duas classes do conjunto de treino. O SVM tenta encontrar um hiperplano que divide as duas classes de maneira a minimizar o risco empírico, ou seja, o erro do conjunto de treinamento.

O hiperplano $f(x) = (\mathbf{w} \cdot \mathbf{x}) + b$ a ser encontrado pelo SVM é aquele que possui uma margem máxima, ou seja, separa um conjunto de vetores sem erros e possui distância á objetos de classes opostas máxima. O hiperplano ótimo é encontrado quando $\langle \mathbf{w}, \mathbf{x} \rangle + b = 0$, sendo w é o vetor-peso e b é o bias.

Para um conjunto de duas classes, $\{-1, 1\}$, os exemplos de treinamento assumem duas restrições:

$$x_i w + b \geq +1, \text{ para } y_i = +1 \quad (3.4)$$

$$x_i w + b \leq -1, \text{ para } y_i = -1 \quad (3.5)$$

Unindo as duas inequações pode-se dizer que:

$$y_i(x_i \cdot w + b) - 1 \geq 0 \quad (3.6)$$

Para maximizar a margem é necessária a minimização da norma $\|w\|$ de acordo com as restrições providas pela Equação 3.6. Para resolver este problema, é necessário utilizar o clássico problema de programação quadrática (HEASRT *et al.*, 1998). É utilizado uma função Lagrangiana definida por (CAMPBELL, 2001):

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i (y_i (w x_i + b) - 1) \quad (3.7)$$

,sendo α_i são multiplicadores de Lagrange e então é necessário solucionar um problema de otimização dual maximizando a Equação 3.8 obedecendo as restrições 3.9.

$$\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j x_i \cdot x_j \quad (3.8)$$

$$\alpha_i \geq 0, i = 1, \dots, n \text{ e } \sum_{i=1}^n \alpha_i y_i = 0 \quad (3.9)$$

Após o passo de encontrar os α_i é possível encontrar os valores do hiperplano $\mathbf{w}^*$ e b^* :

$$\mathbf{w}^* = \sum_{i=1}^n \alpha_i * y_i x_i \quad (3.10)$$

$$b^* = y_j - \langle \mathbf{w}^* . x_j \rangle, \text{ onde } x_j \text{ é um vetor de suporte} \quad (3.11)$$

É possível classificar e , um novo exemplo, de acordo com o sinal da equação $\langle \mathbf{w}^* . e \rangle + b^*$. No entanto, para exemplos não separáveis linearmente, é aplicado no conjunto de dados um novo mapeamento através de uma função Φ , tornando os dados separáveis. Ainda, quando há mais de duas classes a serem classificadas existem duas alternativas:

- **Todos contra todos:** Para cada par de classes é criado um classificador e estas competem duas a duas até que uma classe ganhe pela maioria de classificações corretas.
- **Um contra todos:** é criado um classificador binário para cada classe e atribui-se ao exemplo aquela na qual o classificador apresentou a maior saída. Esta abordagem apresenta menor custo computacional e com resultados semelhantes ao anterior

3.4 Validação Cruzada

Para avaliar o poder de generalização das propostas deste projeto a validação cruzada foi utilizada. Este método separa um conjunto de dados a ser testado em diferentes grupos no qual alguns foram utilizados para treinar o modelo e outros para testá-lo.

Existem diversas maneiras para repartir um conjunto das quais as principais são: *holdout*, *k-fold* e *leave-one-out*. No uso de *holdout*, a base de dados é dividida em dois grupos: um para treinamento e outro para teste. As partições não precisam ser do mesmo tamanho, usualmente é empregado 2/3 do banco de dados para treino e o restante para teste. Já no método *k-fold*, um parâmetro k é utilizado para particionar o conjunto. Neste caso, $k - 1$ subconjuntos são utilizados para treino enquanto o subconjunto restante é testado. Finalmente, o método *leave-one-out* é um caso especial do *k-fold* onde $k = N$, o número total de exemplos do conjunto de dados.

A taxa de acerto é calculada de acordo a média de todas as taxas obtidas para cada teste nos subconjuntos. Também é possível obter o desvio padrão em relação a todos os resultados, se o desvio for muito alto, a proposta não é confiável. É importante que os subconjuntos sejam mutuamente exclusivos já que o objetivo é analisar a capacidade de generalização do método. Além disso, o conjunto pode ser estratificado ou não, significando que cada subconjunto tem um

número uma proporção igual de cada classe. Este trabalho utiliza a validação *k-fold* com $k = 10$ não estratificada (padrão do Weka ([HALL *et al.*, 2009](#))) para análise das propostas.

MÉTODOS DE PRÉ PROCESSAMENTO

Técnicas de pré-processamento possuem como entrada uma imagem e como saída uma modificação desta. O objetivo do processamento de imagens é transformar o dado de entrada para que suas características sejam extraídas mais facilmente. Alguns exemplos de uso de algoritmos de processamento de imagens, não como método final, mas intermediário em algoritmos de visão computacional podem ser encontrados em trabalhos como [GUPTA; JACOBSON; GARCIA, 2007](#). No artigo, o autor testa diversos métodos como binarização, remoção de ruídos e propõe um método chamado 'binarização de erro difuso' baseado em uma abordagem de multiresolução da binarização proposta por Otsu. Estes métodos são aplicados anteriormente à tarefa de OCR (reconhecimento de caracteres ópticos) muito comum em digitalização de documentos.

Em sistemas de reconhecimento facial, é comum utilizar algum tipo de pré-processamento de imagens antes do uso de inteligência artificial. Em [GROSS; BRAJOVIC, 2003](#) os autores propõem um método para resolver o problema presente em muitos sistemas desse tipo de aplicação: a variação de iluminação. O método estima o campo de iluminação para normalizar a luz em toda a imagem e só então aplicar o método de reconhecimento facial propriamente dito. Outro artigo que também utiliza um algoritmo de pré-processamento para resolver o problema de variação de iluminação é [HEUSCH; RODRIGUEZ; MARCEL, 2006](#). O artigo aplica o algoritmo de padrões binários locais (LBP) para gerar uma imagem de padrões, sem calcular o histograma, para servir de entrada para o algoritmo de reconhecimento.

O trabalho de [ZÚÑIGA \(ZÚÑIGA, 2012\)](#), necessita do uso de processamento de imagens para corrigir erros de posicionamento da folha e segmentação da mesma antes de extrair as características de cada planta separadamente. Outro caso é quando se utiliza câmeras multiespectrais em análise de plantações ou imagens de satélite e é necessário separar o espectro para visualizar diferentes alvos e para isso também é utilizado processamento de imagens.

Como este trabalho é focado em textura, os métodos de pré-processamento serão utilizados em uma etapa anterior à aplicação de extratores de características. Um artigo que utiliza

equalização de histograma como método de pré-processamento para análise de mamografias é [GUPTA; UNDRILL, 1995](#). O artigo apresenta um esquemático mostrando que a equalização de histograma é passo importante para aumentar a sensibilidade dos passos seguintes.

Classificar automaticamente tecidos com problemas é muito importante na indústria têxtil para minimização de custos e satisfação do cliente. Em [NEUBAUER, 1992](#), mais uma vez para suavizar o problema de iluminação, o método aplica uma transformação logarítmica de escala de cinza antes da extração de características da imagem, baseada em padrões locais. O artigo [ANITHA; RADHA, 2010](#) aplica diferentes algoritmos de processamento de imagens: ajuste de contraste, ajuste de intensidade, equalização do histograma, binarização e operações morfológicas. Após a aplicação desses métodos em imagens de tecidos, o artigo avaliou as técnicas utilizando erro quadrático médio (mse) e relação sinal-ruído de pico (psnr).

Foram escolhidos para o trabalho algoritmos que contenham propriedade de geração de imagens em diferentes escalas. Simplificadamente, quando se trabalha com múltiplas imagens derivadas em espaço-escala, propriedades diferentes podem ser extraídas quando cada escala é analisada separadamente. Uma melhor explicação sobre esse tipo de abordagem e os métodos utilizados são apresentados nas próximas seções.

4.1 Análise Multiescala

Para nós humanos, a análise de uma imagem é feita por partes. Podemos olhar para uma cena de uma floresta e reconhecer tratar de um conjunto de árvores. No entanto, é preciso analisar com mais enfoque a cena para notar folhas, nervuras, estômatos, dentre outros detalhes que caracterizam a cena dependendo do nível de observação.

Segundo [WITKIN \(WITKIN, 1984\)](#), informações importantes em um sinal estão associados a picos, pontos extremos, singularidades do sinal ou em sua derivada. Como em imagens não é possível calcular a derivada analiticamente e sim estimá-la a partir de uma certa vizinhança, é possível analisar diferentes escalas variando o tamanho dessa vizinhança.

Em 1984, [KOENDERINK](#) percebeu que a derivação de um sinal em espaço-escala pode ser descrita pela equação de calor. Sendo assim, esta pode ser definida como uma solução de equações parciais:

$$\frac{\partial U}{\partial \alpha} = \frac{\partial^2 U}{\partial t^2} \quad (4.1)$$

Para imagens, detalhes presentes em pequena escala são perdidos conforme esta aumenta, pois o sinal é suavizado na convolução da equação de calor (Figura 3). No entanto, características importantes da imagem são preservadas, pois permanecem com o aumento da escala.

Uma abordagem espaço-escala, sendo várias imagens em diferentes escalas são criadas é importante, pois em muitos casos, é necessário remover ruídos e detalhes não necessários para o

Figura 3 – Representação de um sistema multi-escala

Fonte: Elaborada pelo autor.

reconhecimento dos padrões da textura. Analisando por exemplo, cada escala separadamente, é possível extrair apenas características significativas que ocorrem em certo nível (DORINI; LEITE, 2010).

Quando se utiliza este tipo de abordagem é necessário escolher uma maneira de analisar as informações. Três maneiras encontradas na literatura são (JUNIOR; MARCONDES, 1997): utilizar os máximos e mínimos locais de cada escala, selecionar os parâmetro de escala e projetar sobre os eixos tempo e escala. Neste projeto, o método utilizado é a seleção de parâmetro, sendo apenas um parâmetro t e a escala 0 (imagem original) são escolhidos como entrada para os métodos descritores subsequentes. Para a escolha do melhor parâmetro t a ser utilizado é analisado todos os disponíveis e escolhido aquele que retorna uma maior taxa de classificação de cada base. As próximas seções explicam os métodos utilizados para criação das imagens derivadas.

4.2 Abordagem linear

A abordagem linear mais conhecida é a convolução por meio de um núcleo Gaussiano. Para sinais unidimensionais a geração de um sinal suavizado é dada por:

$$[T(x, \sigma)](f) = f(x) * g(x, \sigma) \quad (4.2)$$

, onde g é núcleo Gaussiano de média zero de acordo com:

$$g(x, \sigma) = (2\pi\sigma^2)^{-n/2} \exp\left(\frac{-1}{2\sigma^2} x^T x\right). \quad (4.3)$$

A convolução gera uma difusão isotrópica, ou seja, todos os pontos do sinal são suavizados igualmente. KOENDERINK (KOENDERINK, 1984) demonstrou que a equação gaussiana é a função de Green da equação do calor.

Figura 4 – Imagem original e suavizadas com diferentes gaussianas, $\sigma = 2.0, 3.0$ respectivamente.

Fonte: Adaptada de [USPTex \(2014\)](#).

Uma das características da geração de derivação espaço-escala é a não criação de novas estruturas conforme o aumento da escala. No entanto, com a convolução de um núcleo gaussiano em um sinal bidimensional, novas características são geradas ([LIFSHITZ; PIZER, 1988](#)). Por esse motivo, [KOENDERINK \(KOENDERINK, 1984\)](#) definiu uma nova propriedade para a difusão espaço-escala denominada causalidade, onde define-se que valores de máximo não devem aumentar com o incremento da escala.

Além da criação de novas estruturas, um problema da geração via núcleo gaussiano é o borramento das imagens. Como um mesmo núcleo é convoluido igualmente por toda a superfície da imagem, bordas e não-bordas são difundidas com o aumento da escala. Bordas são dados importantes na extração de características da imagem e a perda dessa informação pode gerar um vetor de características pobre para escalas mais altas ([DORINI; LEITE, 2010](#)). A Figura 4 mostra uma sequência de imagens convoluidas com gaussianas de diferentes sigmas mostrando diferentes escalas (da menor para a maior). É possível perceber que quanto maior o σ , mais embaçada a imagem fica por inteiro, sem preservação das áreas de alto gradiente.

4.3 Abordagens não-linear

Como mencionado anteriormente, abordagens de difusão lineares causam um borramento excessivo das bordas com o aumento da escala. Para isso, diversos autores desenvolveram métodos buscando reduzir esta problemática, aplicando a suavização com menor ou maior força dependendo da região.

4.3.1 Difusão Anisotrópica por Perona-Malik

Uma forma de analisar a imagem em diferentes escalas é convoluí-la com um núcleo gaussiano. As diferentes resoluções são apresentadas por diferentes valores de σ . Quando $\sigma = 0$ a imagem obtida é igual à imagem original. Quanto maior o valor de σ mais borrada a imagem fica.

No entanto, esta abordagem faz com que bordas da imagem sejam perdidas nas escalas mais grossas. Convoluir a imagem com um núcleo gaussiano 'dissolve' a imagem por inteiro, bordas são misturadas com não-bordas e estas perdem sua força e deslocam de posição. Junções de bordas, que são importantes características da imagem, também são perdidas quando a escala é maior. A difusão por gaussiana é chamada de isotrópica, pois apresenta as mesmas propriedades físicas em todas as direções.

Para contornar esse problema, um método proposto por [PERONA; MALIK \(PERONA; SHIOTA; MALIK, 1994\)](#): tem como objetivo gerar imagens em diferentes resoluções sem prejudicar as bordas. Três propriedades foram essenciais para a criação desse método

- **Causalidade:** uma representação mais grosseira não pode criar detalhes falsos não existentes em uma resolução mais fina.
- **Localização Imediata:** a cada resolução as bordas devem ser nítidas e coincidirem com bordas semanticamente significativas na resolução em questão
- **Suavização por Partes:** a suavização deve ocorrer com prioridade em intra-regiões do que entre regiões.

Assim, é possível simplificar a imagem sem perder características importantes. A difusão anisotrópica clássica, nome que é dado ao método, controla o quão 'difundida' será a região de acordo com seu gradiente. Dada a função de difusão anisotrópica ([PERONA; MALIK, 1990](#)):

$$I_t = \text{div}(c(x,y,t)\nabla I) = c(x,y,t)\nabla^2 + \nabla c \cdot \nabla I \quad (4.4)$$

se $c(x,y,t)$ é uma constante, a função acima se torna difusão isotrópica. No entanto, se ao invés disso for escolhida uma função c tal que quanto maior o valor da magnitude gradiente na região, menor é o resultado de c e vice-versa, temos uma difusão que obedece os três termos propostos acima.

Seguindo de perto o livro ([PERONA; SHIOTA; MALIK, 1994](#)) é possível implementar a equação anisotrópica de acordo com a seguinte discretização:

$$I_{t+1}(i,j) = I_t(i,j) + \lambda [c_N \cdot \Delta_N I + c_S \cdot \Delta_S I + c_E \cdot \Delta_E I + c_W \cdot \Delta_W I]_{i,j}^t \quad (4.5)$$

, sendo $0 \leq \lambda \leq \frac{1}{4}$ e N, S, E, W representam as posições norte, sul, leste, oeste em relação ao pixel de posição i, j . O símbolo Δ representa a diferença entre a intensidade dos pixels vizinhos. Por exemplo, $\Delta_N I_{i,j}$ representa a diferença entre o pixel i,j e o pixel à norte $i-1,j$, deste modo $\Delta_N I_{i,j} = (I_{i-1,j}) - (I_{i,j})$ e assim por diante.

Uma possível função c é alguma g tal que $c(x, y, t) = g(\|\nabla I(x, y, t)\|)$ onde g retorne algo proporcionalmente inverso à magnitude do gradiente de $I(x, y, t)$. Os valores de c são computados de acordo com as equações abaixo:

$$c_{N_{i,j}}^t = g(\|(\nabla I)_{i+\frac{1}{2},j}^t\|) \quad (4.6)$$

$$c_{S_{i,j}}^t = g(\|(\nabla I)_{i-\frac{1}{2},j}^t\|) \quad (4.7)$$

$$c_{E_{i,j}}^t = g(\|(\nabla I)_{i,j+\frac{1}{2}}^t\|) \quad (4.8)$$

$$c_{W_{i,j}}^t = g(\|(\nabla I)_{i,j-\frac{1}{2}}^t\|) \quad (4.9)$$

PERONA; MALIK apresentam duas possíveis funções para g :

$$g(\nabla I) = e^{-\left(\frac{\|\nabla I\|}{\kappa}\right)^2} \quad (4.10)$$

$$g(\nabla I) = \frac{1}{1 + \left(\frac{\|\nabla I\|}{\kappa}\right)^2} \quad (4.11)$$

,onde κ é uma constante que pode ser determinada pelo desenvolvedor (CANNY, 1986).

A primeira equação privilegia bordas de alto contraste, enquanto a segunda privilegia grandes regiões. Em qualquer uma das equações, se a magnitude do gradiente é igual a 0, $g(\nabla I)$ retorna 1 de acordo com o que foi proposto por (PERONA; SHIOTA; MALIK, 1994), regiões de baixa frequência devem mais suavizadas. A constante κ pode ser definida manualmente com um valor fixo.

As Figuras 5 apresentam um exemplo de imagem da base Usptex (USPTEX, 2014) utilizando o algoritmo de difusão anisotrópica proposto por PERONA; SHIOTA; MALIK utilizando a equação 4.10, $\lambda = \frac{1}{4}$, $\kappa = 15$ e $t = 10$ (escala). É possível perceber comparando com a imagem da difusão gaussiana ($\sigma = 2$) que o resultado da imagem aplicado à difusão anisotrópica suaviza a imagem mas as bordas são mantidas.

4.3.2 Regularização Forward-Backward da Difusão Anisotrópica

Em (GUIDOTTI; KIM; LAMBERS, 2013), o autor mostra que apesar do método desenvolvido por PERONA; SHIOTA; MALIK ser um modelo interessante, este é mais teórico que prático devido à geração com imagens *cartonizadas*. Por esse motivo, GUIDOTTI; KIM; LAMBERS propôs uma regularização da equação de difusão proposta anteriormente adicionando dois parâmetros $p \in (1, \infty)$ e $\delta > 0$ para evitar o efeito de degrau e ainda manter as

Figura 5 – Três imagens comparativas. A primeira mostra a imagem original. A segunda imagem é o resultado da aplicação da difusão anisotrópica com $t = 10$, $\lambda = \frac{1}{4}$, $\kappa = 15$ e g igual à Equação 4.10. A terceira mostra comparação com a difusão isotrópica, onde as regiões são 'diluídas' igualmente.

Fonte: Adaptada de [USPTex \(2014\)](#).

propriedades importantes da difusão anisotrópica: preservação das bordas. A equação proposta por [GUIDOTTI; KIM; LAMBERS](#) é apresentada a seguir:

$$u_t = \nabla \cdot \left(\left[\frac{1}{1 + K^2 |\nabla u|^2} + \delta |\nabla u|^{p-2} \right] \nabla u \right), \quad (4.12)$$

De acordo com experimentos feitos em ([GUIDOTTI; KIM; LAMBERS, 2013](#)), foi verificado que um parâmetro p próximo à 1 produz resultados melhores.

A adição de dois novos parâmetros de regularização na difusão anisotrópica proporciona o crescimento do gradiente como delimitação no valor máximo de crescimento. Consequentemente, o regime de atraso é confinado para $[1 < |\nabla u| < M(\delta, p)]$ não desenvolvendo descontinuidades. Limitando-se a região de análise, o efeito degrau é substituído por uma micro-rampa com degraus controlados pelos valores p e δ .

Assim como todos os métodos citados, a correta escolha de parâmetros é essencial. Para $p = 1$, por exemplo, o regime de atraso é o mesmo ocorrido no [PERONA; SHIOTA; MALIK](#). Um experimento utilizando $p = 2$ é mostrado em ([GUIDOTTI, 2012](#)) e mostra bons resultados para redução de ruídos nas imagens avaliadas. A Figura 6 mostra a evolução da escala utilizando com $p = 1.1$ e $\delta = 0.25$.

4.3.3 Difusão Anisotrópica Não Local

Desde que [PERONA; SHIOTA; MALIK](#) propuseram seu método de difusão anisotrópica, matemáticos vêm pesquisando novas maneiras de fazer a difusão correta matematicamente ([KICHENASSAMY, 1997; ZHANG, 2006](#)). Apesar de gerar bons resultados para redução de ruídos, o problema analítico fez com que [KICHENASSAMY](#) criassem a expressão "paradoxo Perona-Malik". Deste modo, [GUIDOTTI](#) propôs outro método de regularização do clássico método anisotrópico para evitar o problema de *staircasing*, ou seja, efeito de degrau nas bordas

Figura 6 – Da esquerda pra a direita: imagem original, 10ª e 20ª iteração do algoritmo de regularização forward-backward da difusão anisotrópica.

Fonte: Adaptada de [USPTex \(2014\)](#).

da imagem.

Esta nova abordagem utiliza a derivada fracional de Fourier para a análise das bordas na imagem:

$$u_t = \nabla \left(\frac{1}{1 + |\nabla^{1-\varepsilon} u|^2} \nabla u \right), \text{ where } \varepsilon \in (0, 1) \quad (4.13)$$

Na Equação 4.13, se $\varepsilon = 0$, a suavização é semelhante ao método clássico. Para valores maiores que 1, a derivada fracional se faz necessária. Esta equação é calculada a partir da derivada de Fourier considerando bordas periódicas ([GUIDOTTI, 2009](#)):

$$|\nabla^{1-\varepsilon} u| = \mathcal{F}^{-1} \text{diag}[2\pi|k|^{-\varepsilon}] \mathcal{F}(|\nabla u|), \quad (4.14)$$

, onde

$$\mathcal{F}(u)(k) = \int_{\Omega} e^{-2\pi i k \cdot x} u(x) dx, k \in \mathbb{Z}^2. \quad (4.15)$$

e $\text{diag}[(m_l)_{l \in \mathbb{Z}^n}]$ é a multiplicação matricial com a matriz diagonal com entradas dada por $(0, \dots, 0, \dots, l_j, 0, \dots, 0)$.

O método tem como vantagem analisar a imagem não só localmente mas também globalmente visto que é utilizada a derivação via Fourier. Consequentemente, o algoritmo possui uma robustez maior, pois é capaz de diferenciar bordas de pequenos ruídos. Mais detalhes do método podem ser encontradas em ([GUIDOTTI, 2009](#)). A Figura 7 mostra um exemplo das iterações geradas pelo algoritmo.

4.4 Abordagem Morfológica

Outra maneira de criar diferentes escalas é por meio da aplicação de operações de erosão e dilatação na imagem. Os filtros de choque, do inglês *shock filters*, funcionam 'chocando' a imagem com os operadores citados acima formando rupturas entre regiões de mínimos e máximos locais.

Figura 7 – Diferentes iterações da difusão não local. Da primeira imagem original se derivam as duas outras imagens onde a segunda é referente a 10ª iteração e a terceira à 20ª iteração.

Fonte: Adaptada de [USPTex \(2014\)](#).

Inúmeros filtros de choque são encontrados na literatura, no entanto, este trabalho foca no método desenvolvido por [VACAVANT et al.](#) que utiliza o histograma local suavizado para auxiliar na definição das estruturas de erosão e dilatação. Frequentemente, filtros de choque analisam o laplaciano $\Delta I^{t-1}(p_i)$ para aplicar uma dilatação (se $\Delta I^{t-1}(p_i) < 0$) ou erosão (se $\Delta I^{t-1}(p_i) > 0$) em $I^t(p_i)$. No entanto, essa metodologia não consegue lidar muito bem com ruídos ([VACAVANT et al., 2012](#)). Dessa maneira, o método aqui utilizado, assim como as outras abordagens não lineares, suaviza a imagem de maneira eficiente sem deixar de preservar as bordas (diferente da difusão isotrópica).

Para o cálculo do histograma local suavizado, a seguinte fórmula é utilizada ([KASS; SOLOMON, 2010](#)):

$$\hat{f}(s_k) = \sum_{p_j \in v(p_i)} K(I(p_j) - s_k) W(\|p_i - p_j\|_2) \quad (4.16)$$

, onde p_i é um pixel e $v(p_i)$ seus vizinhos. Usualmente, K e W são utilizados com o um núcleo gaussiano e s_k é o k -ésimo bin do histograma de tamanho n_b . A partir disso, um filtro de mediana suavizado é definido utilizando a integral de K, C:

$$R_k(p_i) = 1 - (C(I(\cdot) - s_k) * W)(p_i) \quad (4.17)$$

Para obter o filtro proposto pelo método, é necessário encontrar um valor de s_k tal que $R_k(p_i) = t$. A Equação 4.18 ($\Delta I(p_i) \in [-1; 1]$ e $\rho \in [-\frac{1}{2}; \frac{1}{2}]$) é responsável pela parametrização das erosões e dilatações. Se o Laplaciano for positivo, erosões com parâmetro $t = \frac{1}{2} - \rho$ são aplicadas. Já para um Laplaciano negativo, são aplicadas dilatações com parâmetro $t = \frac{1}{2} + \rho$,

$$R_k(p_i) = \left(\frac{1}{2} + \rho \Delta I(p_i)\right) \quad (4.18)$$

O algoritmo é iterativo, isso significa que na suavização da imagem e redução de ruídos, sucessivas aplicações do filtro são feitas. Dessa maneira, a cada nova aplicação uma imagem é obtida sendo possível analisá-las pelos descritores. A Figura 8 mostra três exemplos de saída do método com parâmetro $\sigma = 2.8$ e $\rho = 0.1$.

Figura 8 – Exemplo de imagem da base Usptex e a 1ª, 3ª e 5ª iteração do algoritmo de difusão anisotrópica morfológico respectivamente.

Fonte: Elaborada pelo autor.

4.5 Transformada de Distância Euclidiana

O objetivo da transformada de distância (ROSENFELD; PFALTZ, 1968) é associar pixels da imagem à sua menor distância em relação às regiões de interesse. A técnica possui uma grande aplicabilidade em tarefas de visão computacional e computação gráfica. As aplicações mais utilizadas são: obtenção de esqueletos, análise de clusters, análise de dimensão fractal, operações morfológicas (erosão e dilatação) (PARKER, 2010), segmentação (VINCENT; SOILLE, 1991), navegação robótica (CHIN *et al.*, 2001), entre outros.

A ideia principal da transformada de distância é simples. Exemplificando para imagens binárias, onde a região de interesse é a fronteira entre o objeto branco (pixels de valor 1) e o fundo preto (pixels de valor 0), para cada pixel com valor 0 é calculada a distância para o pixel 1 mais próximo e atribuído esse valor ao pixel em questão. De maneira geral, os pixels de fundo podem ser sementes, pontos característicos de uma imagem, regiões ou elementos de Voronoi. Formalmente, a transformada da distância pode ser definida como: dado um objeto O e regiões de interesse O^c , complemento de O em $I(x,y)$, a transformada da distância gera um mapa D do qual para um certo pixel p , o resultado da transformada no ponto será a menor distância de p até O^c :

$$D(p) = \min \{d(p,q) | q \in O^c\} \quad (4.19)$$

A distância euclidiana entre dois pixels p e q é definida como:

$$d(p, q) = \sqrt{(p_x - q_x)^2 + (p_y - q_y)^2} \quad (4.20)$$

O mapa de distâncias pode ser entendido como uma superfície do quais intensidades, valores, são proporcionais às distâncias à O^c . Para imagens não binárias, assim como imagens de texturas, utilizadas nesse trabalho, a transformada de distância também é aplicável com uma pequena variação.

Em uma imagem com níveis de cinza, é possível obter uma superfície onde o eixo $z = f(x, y)$ é a intensidade $G = 0, 1, \dots, 255$ plotando os eixos x e y como as coordenadas do pixel na imagem.

Pensando-se na maneira bruta para encontrar a menor distância de um pixel até o seu fundo é possível imaginar porque o cálculo da transformada é tão caro computacionalmente. Para uma imagem em escala de cinza de tamanho 1200×800 , por exemplo, mais de 244 milhões de voxels devem ser processados. O código força bruta faz para cada voxel fundo uma subtração com todos os voxels de objeto e guarda a menor distância. Considerando a distância euclidiana e um voxel plotado tridimensionalmente a distância é dada pela fórmula $d(x, y, z, p, q, r) = \sqrt{(x - p)^2 + (y - q)^2 + (z - r)^2}$, sendo $f(x, y, z)$ são voxels com valor 1 (pixel do objeto) e $f(p, q, r)$ são voxels com valor 0 (pixel de fundo). O artigo (JONES; BAERENTZEN; SRAMEK, 2006) faz uma revisão em métodos da literatura que implementam a transformada de distância em imagens com níveis de cinza.

As Figuras 9, 10, 11 explicam passo a passo o funcionamento do algoritmo proposto por (SAITO; TORIWAKI, 1994). No algoritmo de SAITO; TORIWAKI, é implementado a distância ao quadrado ao pixel mais próximo ao voxel de valor 1 ($v(x, y, z) = 1$, se $I(x, y) = z$ na imagem original). Três passos são necessários para obter o resultado final. Primeiramente é calculada a distância ao quadrado até o voxel de valor 1 na mesma linha. O segundo passo verifica se não há um voxel mais próximo com valor 1 na coluna. Por último, como a imagem em níveis de cinza foi transformada em um cubo onde a terceira dimensão representa a intensidade, o algoritmo calcula a distância em relação a esse terceiro eixo. As Equações 4.21, 4.22 e 4.23 representam os três passos para obter a distância euclidiana quadrada proposta por SAITO; TORIWAKI. Nas três equações a imagem em escala de cinza já foi convertida para uma imagem binária 3D f .

$$g_{ijk} = \min_x \{ (i - x)^2, f_{xjk} = 0, 1 \leq x \leq L \}. \quad (4.21)$$

$$h_{ijk} = \min_y \{ g_{iyk} + (j - y)^2, 1 \leq y \leq M \}. \quad (4.22)$$

$$s_{ijk} = \min_z \{ h_{ijz} + (k - z)^2, 1 \leq z \leq N \}. \quad (4.23)$$

Figura 9 – Passo 1: Inicialmente a imagem em níveis de cinza é transformada em uma imagem binária 3D. Para cada posição (x,y,z) do voxel, esta recebe o valor de 1 se $I(x,y) = 1$ e 0 do contrário. Quando o voxel tem valor 1, a distância para o pixel de interesse é 0 (representado por quadrados pretos). Do contrário, tem valor ∞ . Depois a cada voxel de valor ∞ é calculado a distância quadrada mínima ao voxel 0 mais próximo na linha x .

Fonte: Elaborada pelo autor.

Na prática, uma imagem em níveis de cinza quando processada pela transformada de distância retorna um cubo de tamanho $M \times N \times D$. M é o tamanho da imagem em linhas e N o número de colunas. D é um valor a ser escolhido pelo usuário e representará o plano máximo no eixo z do cubo. Apesar de não fielmente ligada a multi-escala, assim como os outros métodos já mencionados, a criação deste cubo gera um leque de diferentes imagens quando analisado cada eixo z_i deste cubo. É possível perceber pelas imagens na Figura 12 que quanto mais longe da superfície da imagem (quando maior o z_i) avaliado, menos detalhes são percebidos. Neste

Figura 10 – Passo 2: a imagem gerada no passo 1 (Figura 9) é novamente processada. Para cada pixel não 0 é calculado mínimo entre a soma de cada coluna e a distância ao quadrado do pixel em questão até a coluna a somada.

Fonte: Elaborada pelo autor.

projeto, o eixo z_i é também t , um parâmetro utilizado durante todo o projeto para se referir a escala da imagem.

De outro modo, a transformada aplicada a um contorno equivale a repetidamente dispor círculos de raios diferentes em todos os pontos do contorno permitindo o cálculo do perímetro da estrutura (BRUNO *et al.*, 2008). Pela dilatação que ocorre no processo do algoritmo, quando há uma região de alto contraste quanto mais afastado dessa região no cubo é possível perceber que essa diferença de contraste é imperceptível.

Figura 11 – Passo 3: O último passo é semelhante ao segundo. Porém a soma ocorre com os pixels na mesma linha e coluna mas diferente plano.

Fonte: Elaborada pelo autor.

Figura 12 – Evolução das iterações (cortes no eixo z) da transformada da distância da primeira imagem. As imagens seguintes representam as iterações 20, 25 e 35 respectivamente.

Fonte: Elaborada pelo autor.

METODOLOGIA

O reconhecimento de padrões é tarefa fundamental na classificação de imagens de textura. Além disso, ela está presente em todos os objetos tornando uma característica importante a ser analisada para classificação, pois possui uma quantidade maior de informações em comparação com cor e formato dependendo da aplicação.

Usualmente pesquisas em reconhecimento de textura têm como objetivo criar novos métodos de extração de características que extraiam as especialidades de cada tipo de textura de forma a aumentar a taxa de acerto. São métodos como os citados no Capítulo 2 que retornam um vetor numérico para representá-las.

Nos algoritmos descritores é comum utilizar a abordagem de multi-escala para analisar a imagem em vários níveis de detalhamento (COBURN; ROBERTS, 2004; FLORINDO; BRUNO, 2013; BACKES; BRUNO, 2009). Utilizar uma fase de pré-processamento com algoritmo de cunho multi-escala anterior ao uso de extratores (não multi-escala) é o propósito deste trabalho. A ideia é explorar as diferentes informações que a análise em vários níveis pode oferecer para potencializar a extração de características.

Todos os algoritmos de pré-processamento discutidos no Capítulo 4 geram uma sequência de imagens em diferentes escalas. É pressuposto neste trabalho que cada uma delas expõe características diferentes da textura. Se alguma escala contiver características mais significativas da imagem, por consequência a taxa de acerto se elevará. Portanto, para cada escala gerada uma taxa de acerto na classificação é computada.

De maneira simplificada, a abordagem é construída por 3 passos:

- **Fase de Pré Processamento:** as imagens originais da base de dados são processadas pelo método e txn novas imagens são geradas, sendo t é o número total de escalas e n o total de imagens da base.
- **Fase de Extração de Características:** são extraídas as características de todas as imagens

processadas e da imagem original gerando para cada imagem original da base n vetores de características v_i , onde i se refere a cada escala gerada pelo método de pré-processamento, e um vetor v_o representando o vetor característica da imagem original. O vetor de características final para cada escala i ($1 \leq i \leq t$) é a concatenação do vetor característica da imagem original com o vetor da imagem da iteração i , ou seja, $v_i^f = \{v_o, v_i\}$.

- **Fase de Classificação:** como mencionado anteriormente, para cada escala computada é gerado uma taxa de acerto equivalente.

A Figura 13 resume graficamente a metodologia utilizada no trabalho.

Figura 13 – Diagrama do método proposto. Primeiro todas as imagens do banco são transformadas pelo método de pré-processamento (pp) gerando k novas imagens para cada imagem original. O segundo passo é analisar todas as imagens (originais e transformadas) com um descritor d . Cada vetor descrito da iteração i ($1 \leq i \leq k$) concatenado com o vetor de sua respectiva imagem original é utilizado pelo espaço do classificador para obter a taxa de acerto com uso de validação cruzada.

Fonte: Elaborada pelo autor.

5.1 Bases de Dados Utilizadas

Quatro bases de dados foram utilizadas para avaliar o potencial de reconhecimento de texturas. Elas são descritas a seguir:

5.1.1 *Brodatz*

Muito famosa na área, a base Brodatz é composta por 111 classes com 10 exemplos cada. Em níveis de cinza, as imagens foram retiradas de uma álbum de fotografia ([BRODATZ, 1966](#)). De cada imagem original, foram criadas 10 novas imagens de tamanho 200x200 compondo assim uma classe. As imagens não possuem variação de luminosidade, ponto de vista ou escala. A Figura 14 mostra um exemplo das imagens desta base.

Figura 14 – Exemplos de imagens de diferentes classes encontradas no banco de dados Brodatz.

Fonte: Elaborada pelo autor.

5.1.2 *Usptex*

Contendo 2292 imagens divididas em 191 classes com 12 exemplos cada, esta base de dados possui imagens de textura como sementes, arroz, tecido, vegetação, estrada, entre outros (Figura 15) ([USPTEX, 2014](#)). As imagens possuem tamanho 128x128 produzidas a partir de uma imagem 512x384 sem sobreposição. As imagens da base são coloridas (RGB), mas convertidas para escala de cinza no trabalho.

5.1.3 *Outex*

A terceira base utilizada contém 68 classes com 20 exemplos cada, totalizando 1360 imagens de tamanho 128x128 ([OJALA et al., 2002](#)). Assim como a base Usptex, a base possui imagens coloridas que foram convertidas para escala de cinza. As imagens contém superfícies

Figura 15 – Exemplos de imagens de diferentes classes encontradas no banco de dados Usptex.

Fonte: Elaborada pelo autor.

e cenas naturais com variação em termos de escala, iluminação e ponto de vista. A Figura 16 mostra uma exemplo de imagens contidas da base.

Figura 16 – Exemplos de imagens de diferentes classes encontradas no banco de dados Outex.

Fonte: Elaborada pelo autor.

5.1.4 Vistex

Por último, a base de dados Vistex, contém 864 imagens no total: 54 classes com 16 exemplos cada (PICKARD *et al.*, 1995). Muito utilizada na literatura, a base contém uma variedade de imagens de cenas naturais em diferentes ângulos, escalas e condições de iluminação. As imagens coloridas foram convertidas para níveis de cinza e um exemplo das imagens é visto na Figura 17.

5.2 Configuração dos Métodos

Para as diferentes bases, os métodos foram aplicados com os mesmos parâmetros. Os parâmetros dos algoritmos das fases de análise de textura e classificação são definidos nesta seção, já os parâmetros de pré-processamento são definidos no Capítulo 6, juntamente com os resultados. Todos os métodos foram implementados em MATLAB e a ferramenta *Weka* (HALL *et al.*, 2009) foi utilizada para geração dos resultados e validação cruzada.

Figura 17 – Exemplos de imagens de diferentes classes encontradas no banco de dados Vistex.

Fonte: Elaborada pelo autor.

5.2.1 Métodos de Extração de Características

- **LBP:** É utilizado o LBP clássico com janela 3x3 totalizando em $2^8 = 256$ características para cada imagem.
- **Histograma:** após a geração do histograma, 6 características são geradas para cada imagem: média, variância, assimetria, curtose, energia e entropia.
- **GLCM:** Para o uso do GLCM, 4 características (correlação, contraste, energia, homogeneidade) para cada par $(\Delta x, \Delta y)$ foi gerada. Foram utilizados os pares (0 1), (-1 1), (-1 0), (-1 -1), (0 2), (-2 2), (-2 0) e (-2 -2) para $(\Delta x, \Delta y)$
- **GLDM:** Para calcular a imagem diferença foram utilizado os pares $(\Delta x, \Delta y) = \{(0, dx), (-dx \ dy), (0 \ d), (-dx \ -dy)\}$, onde $dx = dy = d$ e $d = \{1, 2, 4, 8\}$. A partir da função densidade de cada imagem gerada (16 no total), foi calculada 4 características para cada imagem: contraste, segundo momento angular, média e entropia totalizando $4 \times 16 = 64$ características para cada imagem.
- **Gabor:** Neste método, 8 escalas com 5 orientações foram aplicados gerando um vetor de características de 40 posições.
- **Fourier:** São analisados 64 (8 ângulos e 8 frequências) seções da imagem transformada por Fourier obtendo 64 características.
- **Fractal:** É utilizado o algoritmo de Boulingand–Minkowski (RIBAS *et al.*, 2015). Neste, é utilizado uma esfera de raio r para dilatar a imagem e calculado assim o volume $v(r)$. O vetor de característica possui então a concatenação do logaritmo desses volumes para cada raio. Foi utilizado um raio máximo de 9.

5.2.2 Métodos de Classificação

Os métodos de classificação utilizados para testar a proposta são o KNN e o Naive Bayes. Os métodos foram escolhidos visto sua simplicidade e bons resultados obtidos. O algoritmo SVM, apesar de muito famoso, foi testado para algumas combinações mas descartados devido seu tempo de processamento e resultados muito próximos aos obtidos pelo outros dois métodos.

O KNN, foi aplicado com parâmetros de $k = 1, 3, 5, 7, 9$. Além disso, foi utilizada validação cruzada com o método k-fold ($k = 10$) para testar a capacidade de generalização dos métodos propostos.

RESULTADOS

Este capítulo mostra alguns resultados obtidos durante este trabalho. Análises foram feitas em todos os resultados e os classificadores KNN com $k = 1$ e Naive Bayes obtiveram as maiores taxas de acerto de maneira geral para todos os métodos. Portanto, os resultados com esses classificadores são mostrados neste capítulo enquanto que outros resultados com diferentes parâmetros do KNN, $k = 3, 5, 7$ e 9 , são mostrados do Apêndice A para melhor organização.

6.1 Difusão Linear

Como a maneira mais conhecida de difusão aplicada as imagens, é imprescindível a utilização da gaussiana como método de pré-processamento. Para cada iteração i , a imagem é convoluída com um valor de $\sigma = 0.5 * i$. 150 iterações são geradas no total e para cada uma delas, uma taxa de acerto é produzida. Tabelas 1, 13, 14, 15, 16 e 2 apresentam os resultados para as quatro bases analisadas. Os melhores resultados foram obtidos utilizando os classificadores Naive Bayes e KNN com $k = 1$. Para as bases Brodatz, Usptex e Vistex o LBP foi o método que atingiu a maior taxa de acerto com a aplicação da gaussiana antes da extração de características. Já para a base Outex, o método GLDM obteve a maior taxa de acerto, 97,79%. No entanto, vários métodos também alcançaram um grande salto em sua taxa de acerto com utilização do pré-processamento como Gabor (até 11%), GLCM (até 13 %) Fractal (até 26%), Fourier (até 12%) e Histograma (até 37%).

Se formos analisar o quanto o método proposto auxiliou na melhoria da extração de características, é possível perceber que o GLDM foi o que mais se beneficiou. Com o classificador Naive Bayes, as bases propostas tiveram um crescimento na taxa de acerto de 24.42%, 41.54%, 39.93% e 32.90% para as bases Brodatz, Outex, Vistex e Usptex respectivamente. Como vantagem, a aplicação da difusão linear auxiliou positivamente nos métodos descritores na maioria dos casos. Em poucos casos, como na utilização do método com o descritor Histograma na base Vistex o ganho foi zero e o único resultado, considerando a melhor iteração, negativo no

uso do pré-processamento isotrópico foi obtido com o descritor GLCM na base Vistex (KNN, $k = 1$).

As Figuras 18, 19, 20 e 21 mostram a evolução das taxas de acerto para cada iteração em todas as bases e métodos. Para o gráfico 18, relativo a base Vistex, é possível perceber na maioria dos gráficos uma alta de taxa de acerto para pequenos valores de σ e baixa com o aumento da iteração. Porém, para os descritores Fractal, Histograma e GLCM todas as iterações otimizam o descritor clássico, no entanto, para os métodos Gabor e Fractal o incremento na taxa de reconhecimento ocorre apenas para as primeiras iterações.

Para a base Brodatz (Figura 19), as taxas de acerto dos métodos originais são mais altas naturalmente, visto que a base é mais fácil de ser classificada pois não há diferenças de iluminação, escala e ponto de vista nas imagens da base. Para todos os métodos descritores, ocorre um ganho nas primeiras iterações e uma queda na taxa de acerto a medida que as iterações crescem. O método onde existe uma otimização em um maior número de iterações é o Fractal.

A Figura 20 mostra os resultados para todas as iterações na base Outex. É percebido um elevado ganho nas iterações iniciais para todos os descritores. Nos métodos extratores Histograma, GLCM, GLDM e Fractal, o uso da Gaussiana não resultou em ganho negativo. No entanto, nesses métodos há uma convergência para o resultado do método aplicado nas imagens originais, ou seja, um ganho nulo na taxa de acerto.

Por fim, o uso da gaussiana na base Usptex (Figura 21) teve ótimo resultado aliado aos descritores Histograma, GLCM, GLDM e Fractal. Para estes métodos, não houve perda na taxa de sucesso com o uso das imagens modificadas, mas apenas proveito. Para os outros métodos, a proposta incrementa o resultado final do classificador nas primeiras iterações mas existe um declínio na taxa de classificação com a evolução da difusão.

Figura 18 – Taxas de acerto obtidas pela utilização da gaussiana convolvida a imagem original. É mostrado a evolução para todos os descritores utilizando a base Vistex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 19 – Taxas de acerto obtidas pela utilização da gaussiana convolvida à imagem original. É mostrado a evolução para todos os descritores utilizando a base Brodatz e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 20 – Taxas de acerto obtidas pela utilização da gaussiana convolvida à imagem original. É mostrado a evolução para todos os descritores utilizando a base Outex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 21 – Taxas de acerto obtidas pela utilização da gaussiana convoluída à imagem original. É mostrado a evolução para todos os descritores utilizando a base Usptex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Tabela 1 – Resultados da aplicação de gaussiana como método de pré-processamento com diferentes extratores e KNN (k = 1) como classificador.

	KNN, k = 1							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
G+LBP	95.59(1.19)	4	79.63(1.97)	7	97.69(1.90)	10	79.01(1.58)	5
LBP	93.96(1.70)	-	72.50(2.48)	-	94.21(2.74)	-	73.65(2.47)	-
ganho	1.62	↑	7.13	↑	3.47	↑	5.37	↑
G+Histogram	31.89 (4.24)	19	32.21 (3.77)	6	36.23 (4.66)	1	13.96 (2.12)	1
Histogram	29.37(3.63)	-	25.15 (2.59)	-	36.00 (5.07)	-	13.05 (1.22)	-
ganho	2.52	↑	7.06	↑	0.23	↑	0.92	↑
G+GLCM	90.36 (3.03)	1	74.93 (3.49)	1	91.20 (2.21)	3	68.11 (2.51)	1
GLCM	90.00(2.77)	-	72.72 (5.19)	-	87.38 (3.56)	-	63.74 (4.23)	-
ganho	0.36	↑	2.21	↑	3.82	↑	4.36	↑
G+GLDM	91.08(2.60)	1	97.79(3.42)	1	85.07(3.34)	4	59.29(2.98)	1
GLDM	79.64(1.48)	-	95.74(3.75)	-	64.24(6.62)	-	38.74(2.27)	-
ganho	11.44	↑	2.06	↑	20.83	↑	20.55	↑
G+Fourier	88.20(2.29)	5	78.24(3.05)	6	89.58(3.09)	8	65.79(2.50)	4
Fourier	85.32(2.40)	-	68.75(2.76)	-	80.44(3.60)	-	56.85(3.23)	-
ganho	2.88	↑	9.49	↑	9.14	↑	8.94	↑
G+Gabor	94.05(2.25)	8	82.28(3.42)	7	94.91(2.91)	5	78.80(2.48)	6
Gabor	90.90(2.10)	-	72.06(2.11)	-	88.43(1.93)	-	70.59(2.71)	-
ganho	3.15	↑	10.22	↑	6.48	↑	8.20	↑
G+Fractal	72.61(3.53)	4	63.01(4.17)	7	71.53(2.84)	4	39.27(2.37)	1
Fractal	57.30(4.06)	-	48.46(3.93)	-	52.31(5.80)	-	29.01(3.12)	-
ganho	15.32	↑	14.56	↑	19.21	↑	10.25	↑

Fonte: Elaborada pelo autor.

6.2 Difusão Anisotrópica por Perona-Malik

Para o método clássico de difusão anisotrópica, 150 iterações foram processadas. A função g escolhida para análise da região está descrita na Equação 6.1, com $\kappa = 1$ e $\lambda = 0.25$. Os resultados obtidos para todos os classificadores e bases testadas estão dispostos nas Tabelas 3, 17, 18, 19, 20 e 4.

$$g(\nabla I) = \frac{1}{1 + (\frac{\|\nabla I\|}{\kappa})^2} \quad (6.1)$$

Analizando os resultados das tabelas, o melhor resultado obtido foi na base Brodatz, onde o LBP aliado a difusão obteve taxa de acerto de 97,65% (KNN, k = 1). As maiores taxas de acerto para as outras bases também foram obtida pela combinação com o LBP. Assim como no método isotrópico, as melhores taxas de acerto, de maneira geral, são alcançadas com KNN (k = 1) e Naive Bayes.

A influência das imagens derivadas na extração de características pelo GLDM foi altamente positiva. Porém, para os métodos Histograma e GLCM, a técnica não obteve o mesmo resultado. Enquanto o ganho para base Usptex no GLDM foi de 30.27% (Naive Bayes), para os

Tabela 2 – Resultados da aplicação de gaussiana como método de pré-processamento com diferentes extratores e Naive Bayes como classificador.

	Naive Bayes							
	Brodatz			Outex		Vistex		Usptex
	melhor i			melhor i		melhor i		melhor i
G+LBP	95.50 (1.82)	3		83.01 (3.72)	8	96.53 (1.32)	3	81.33 (2.12)
LBP	95.05(1.60)	-		80.81 (3.47)	-	95.49 (3.27)	-	78.71 (1.44)
ganho	0.45	↑		2.21	↑	1.04	↑	2.62
G+Histogram	50.00 (5.61)	8		54.93 (3.87)	7	41.09 (4.56)	2	36.17 (1.99)
Histogram	44.68(4.31)	-		27.21 (2.45)	-	3.24 (4.32)	-	25.83 (1.38)
ganho	5.32	↑		27.72	↑	37.85	↑	10.34
G+GLCM	90.81 (2.94)	4		76.10 (3.08)	7	85.65 (4.48)	5	59.73 (2.55)
GLCM	84.77(2.80)	-		62.35 (4.63)	-	73.03 (5.14)	-	47.86 (3.23)
ganho	6.04	↑		13.75	↑	12.62	↑	11.87
G+GLDM	85.32 (2.59)	3		60.07 (3.18)	1	73.73 (6.97)	4	52.75 (4.12)
GLDM	60.90(4.48)	-		18.53 (1.92)	-	33.80 (4.03)	-	19.85 (1.55)
ganho	24.41	↑		41.54	↑	39.93	↑	32.90
G+Fourier	86.40 (2.94)	5		69.93 (2.63)	6	85.07 (1.57)	5	56.15 (3.02)
Fourier	81.44(2.95)	-		56.62 (3.70)	-	71.99 (3.09)	-	48.43 (2.98)
ganho	4.95	↑		13.31	↑	13.08	↑	7.72
G+Gabor	92.61 (2.00)	5		75.15 (4.06)	6	91.20 (1.90)	5	71.77 (2.31)
Gabor	89.10(3.02)	-		65.22 (2.48)	-	84.14 (3.40)	-	62.52 (2.85)
ganho	3.51	↑		9.93	↑	7.06	↑	9.25
G+Fractal	60.63 (5.22)	5		46.69 (2.65)	8	58.33 (4.70)	5	28.66 (2.57)
Fractal	40.45(2.56)	-		20.15 (2.78)	-	31.37 (3.32)	-	15.36 (2.13)
ganho	20.18	↑		26.54	↑	26.97	↑	13.31

Fonte: Elaborada pelo autor.

métodos Histograma e GLCM a perda foi de 0.96% e 6.41% respectivamente, considerando o mesmo classificador.

Comparando o melhor resultado em taxa de acerto, LBP, obtido com o uso da difusão isotrópica e da difusão anisotrópica, o segundo leva vantagem em todas as bases. Na base Brodatz, por exemplo, o primeiro método obteve taxa de acerto de 95.59% enquanto o mesmo método de extração com o novo método de pré-processamento resultou em 97.66%, um aumento de 2.07% (KNN, $k = 1$).

A Figura 22 mostra as taxas de acerto de todas as iterações para os métodos descritores associados à difusão anisotrópica e a reta vermelha mostra a taxa e acerto obtida pelo método original para a base Vistex. Os gráficos do LBP e do GLCM possuem uma grande variação nas taxas de sucesso, porém todas as iterações mostram um ganho positivo em relação ao método tradicional. Como pode ser visto, o GLCM foi o único método no qual o uso difusão anisotrópica clássica foi pior que o método original. O restante dos métodos, Fourier, Gabor e Fractal apresentam taxas consistentes, comparando os resultados das iterações, e influência positiva em todas as iterações.

Para os gráficos da base Brodatz, a Figura 23 apresenta resultados semelhantes aos da base Vistex. No entanto, para o método descritor Histograma, o uso da base transformada não potencializou o método original, nenhuma iteração é capaz de superar o método puro.

Na base Outex, o gráfico do LBP (Figura 24) mostra uma grande oscilação no resultado proposto. No entanto, poucas iterações apresentam uma saída negativa em relação à taxa de acerto do LBP tradicional. Para os métodos descritores GLDM, Fourier, Gabor e Fractal, a proposta potencializa a taxa de acerto em todas as iterações.

Finalmente, a base Usptex apresenta o mesmo comportamento da Outex, mostrando um resultado negativo com o uso da difusão anisotrópica clássica aliada aos extratores GLCM e Histograma, porém muito positiva para os outros métodos (nenhuma iteração avaliada apresenta um resultado menor comparado ao descritor aplicado nas imagens originais).

Figura 22 – Taxas de acerto obtida pela utilização da difusão anisotrópica clássica aplicada nas imagens originais. É mostrado a evolução para todos os descritores utilizando a base Vistex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 23 – Taxas de acerto obtida pela utilização da difusão anisotrópica clássica aplicada nas imagens originais. É mostrado a evolução para todos os descritores utilizando a base Brodatz e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 24 – Taxas de acerto obtida pela utilização da difusão anisotrópica clássica aplicada nas imagens originais. É mostrado a evolução para todos os descritores utilizando a base Outex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 25 – Taxas de acerto obtida pela utilização da difusão anisotrópica clássica aplicada nas imagens originais. É mostrado a evolução para todos os descritores utilizando a base Usptex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Tabela 3 – Resultados obtidos com a aplicação do algoritmo de difusão anisotrópica clássico nas imagens originais das bases. O ganho é resultante da diferença entre o melhor resultado quando se aplica a difusão e o resultado em qualquer aplicação de pré-processamento na avaliação do KNN, $k = 1$

	KNN ($k = 1$)							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
PM+LBP	97.66 (0.77)	22	73.60 (2.80)	142	98.61 (1.75)	73	82.72 (1.69)	31
LBP	93.96(1.70)	-	72.50 (2.48)	-	94.21 (2.74)	-	73.65 (2.47)	-
ganho	3.69	↑	1.10	↑	4.40	↑	9.08	↑
PM+Histogram	25.05 (4.43)	16	22.87 (1.87)	119	35.88 (4.64)	62	12.52 (1.88)	4
Histogram	29.37(3.63)	-	25.15 (2.59)	-	36.00 (5.07)	-	13.05 (1.22)	-
ganho	-4.32	↓	-2.28	↓	-0.12	↓	-0.52	↓
PM+GLCM	70.54 (3.05)	5	53.53 (5.14)	2	78.36 (4.49)	1	53.93 (3.82)	2
GLCM	90.00(2.77)	-	72.72 (5.19)	-	87.38 (3.56)	-	63.74 (4.23)	-
ganho	-19.46	↓	-19.19	↓	-9.03	↓	-9.82	↓
PM+GLDM	91.17 (1.58)	60	67.21 (3.01)	59	81.83 (4.10)	74	55.89 (2.86)	58
GLDM	79.64(1.48)	-	50.59 (3.75)	-	64.24 (6.62)	-	38.74 (2.27)	-
ganho	11.53	↑	16.62	↑	17.59	↑	17.15	↑
PM+Fourier	86.85 (1.70)	138	71.69 (4.10)	11	84.72 (3.01)	65	64.49 (3.35)	42
Fourier	85.32(2.40)	-	68.75 (2.76)	-	80.44 (3.60)	-	56.85 (3.23)	-
ganho	1.53	↑	2.94	↑	4.28	↑	7.64	↑
PM+Gabor	93.15 (1.29)	117	75.37 (2.46)	21	90.86 (2.61)	131	76.96 (2.49)	8
Gabor	90.90(2.10)	-	72.06 (2.11)	-	88.43 (1.93)	-	70.59 (2.71)	-
ganho	2.25	↑	3.31	↑	2.43	↑	6.37	↑
PM+Fractal	65.05 (3.75)	128	50.66 (3.68)	109	64.58 (5.64)	129	43.54 (2.45)	71
Fractal	57.30(4.06)	-	48.46 (3.93)	-	52.31 (5.80)	-	29.01 (3.12)	-
ganho	7.75	↑	2.21	↑	12.27	↑	14.53	↑

Fonte: Elaborada pelo autor.

6.3 Regularização Forward-Backward da Difusão Anisotrópica

O primeiro método de regularização da difusão anisotrópica utiliza além dos parâmetros κ e λ , outros dois parâmetros p e δ . Como sugestão do autor, a p foi atribuído o valor de 1.1 e para δ o valor de 0.1. Os valores de κ e λ receberam os mesmos atributos do método clássico, $\kappa = 1$ e $\lambda = 0.25$, e mesmo número de iterações, 150. As Tabelas 5, 21, 22, 23, 24 e 6 mostram os resultados.

O maior resultado foi atingido com o método proposto associado ao LBP nas bases Brodatz (97.57%), Vistex (98.73%) e Usptex (88.52%). A base Outex atingiu melhor resultado com a análise por fractal sem o uso de pré-processamento (95.96%, KNN, $k = 1$), nesse caso, a proposta não alcançou o melhor resultado entre todos os gerados com esse método de pré-processamento. No entanto, para o restante dos classificadores, houve um ganho com o pré-processamento para o mesmo método de extração. Na classificação por Naive Bayes, por exemplo, ocorreu um incremento na taxa de acerto em relação ao algoritmo original de 16.32%.

Nas quatro bases, o uso da regularização forward-backward não melhorou a extração para os descritores Histograma e GLCM. Porém, assim como nos demais métodos de multi-escala, o GLDM foi o mais privilegiado com a técnica. A Figura 26 mostra todas as taxas de acerto para

Tabela 4 – Resultados obtidos com a aplicação do algoritmo de difusão anisotrópica clássico nas imagens originais das bases. O ganho é resultante da diferença entre o melhor resultado quando se aplica a difusão e o resultado em qualquer aplicação de pré-processamento na avaliação do Naive Bayes

	Naive Bayes							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
PM+LBP	96.94 (1.20)	11	83.38 (3.98)	18	97.45 (1.82)	10	85.47 (1.63)	39
LBP	95.05(1.60)	-	80.81 (3.47)	-	95.49 (3.27)	-	78.71 (1.44)	-
ganho	1.89	↑	2.57	↑	1.97	↑	6.76	↑
PM+Histogram	40.90 (4.25)	130	30.37 (1.77)	84	49.88 (4.75)	7	24.87 (2.88)	81
Histogram	44.68(4.31)	-	27.21 (2.45)	-	48.38 (4.32)	-	25.83 (1.38)	-
ganho	-3.78	↓	3.16	↑	1.50	↑	-0.96	↓
PM+GLCM	76.22 (3.68)	142	58.53 (2.15)	112	69.21 (4.14)	2	41.45 (3.20)	3
GLCM	84.77(2.80)	-	62.35 (4.63)	-	73.03 (5.14)	-	47.86 (3.23)	-
ganho	-8.56	↓	-3.82	↓	-3.82	↓	-6.41	↓
PM+GLDM	84.14 (2.29)	119	52.87 (4.03)	12	68.06 (6.33)	141	50.13 (3.82)	27
GLDM	60.90(4.48)	-	18.53 (1.92)	-	33.80 (4.03)	-	19.85 (1.55)	-
ganho	23.24	↑	34.34	↑	34.26	↑	30.28	↑
PM+Fourier	84.14 (3.07)	111	67.43 (3.50)	43	80.79 (2.37)	1	61.82 (2.70)	76
Fourier	81.44(2.95)	-	56.62 (3.70)	-	71.99 (3.09)	-	48.43 (2.98)	-
ganho	2.70	↑	10.81	↑	8.80	↑	13.39	↑
PM+Gabor	90.99 (2.72)	29	74.49 (4.29)	36	89.58 (3.14)	1	75.61 (3.65)	11
Gabor	89.10(3.02)	-	65.22 (2.48)	-	84.14 (3.40)	-	62.52 (2.85)	-
ganho	1.89	↑	9.26	↑	5.44	↑	13.09	↑
PM+Fractal	46.85 (2.78)	132	34.85 (4.36)	53	46.06 (5.20)	51	29.36 (2.17)	94
Fractal	40.45(2.56)	-	20.15 (2.78)	-	31.37 (3.32)	-	15.36 (2.13)	-
ganho	6.40	↑	14.71	↑	14.70	↑	14.01	↑

Fonte: Elaborada pelo autor.

os métodos com a base Vistex (classificador Naive Bayes). É possível notar o benefício causado pela adição da difusão na extração de características dos métodos Fractal, Fourier, Gabor, GLDM e LBP. O método Histograma mostra poucas iterações com saldo positivo enquanto o GLCM original obtém melhor resultado comparado a todas as iterações da proposta.

Nas bases Brodatz (Figura 27) e Usptex (Figura 29), o Histograma nas imagens transformadas ainda teve um desempenho pior, pois nenhuma taxa de acerto supera a do método aplicado nas imagens originais. Para o restante dos métodos, a regularização forward-backward funcionou similar ao que foi observado na base Vistex.

Figura 26 – Taxas de acerto obtidas pela utilização da regularização forward-backward da difusão anisotrópica nas imagens originais. É mostrado a evolução para todos os descritores utilizando a base Vistex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 27 – Taxas de acerto obtidas pela utilização da regularização forward-backward da difusão anisotrópica nas imagens originais. É mostrado a evolução para todos os descritores utilizando a base Brodatz e classificador Naïve Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 28 – Taxas de acerto obtidas pela utilização da regularização forward-backward da difusão anisotrópica nas imagens originais. É mostrado a evolução para todos os descritores utilizando a base Outex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 29 – Taxas de acerto obtidas pela utilização da regularização forward-backward da difusão anisotrópica nas imagens originais. É mostrado a evolução para todos os descritores utilizando a base Usptex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Tabela 5 – Resultados da aplicação da regularização forward-backward da difusão anisotrópica, são 150 iterações testas e a coluna melhor i apresenta a iteração que mostrou o melhor resultado. A tabela mostra os resultados para KNN, $k = 1$.

	KNN, $k = 1$							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
FBR+LBP	97.21 (0.83)	20	78.53 (2.86)	74	98.73 (1.36)	82	84.55 (2.29)	33
LBP	93.96(1.70)	-	72.50 (2.48)	-	94.21 (2.74)	-	73.65 (2.47)	-
ganho	3.24	↑	6.03	↑	4.51	↑	10.91	↑
FBR+Histogram	24.32 (2.58)	148	23.97 (3.03)	142	34.84 (4.12)	56	12.61 (1.60)	43
Histogram	29.37(3.63)	-	25.15 (2.59)	-	36.00 (5.07)	-	13.05 (1.22)	-
ganho	-5.05	↓	-1.18	↓	-1.16	↓	-0.44	↓
FBR+GLCM	69.64 (3.83)	4	51.99 (4.58)	2	77.66 (4.55)	1	53.66 (3.55)	1
GLCM	90.00(2.77)	-	72.72 (5.19)	-	87.38 (3.56)	-	63.74 (4.23)	-
ganho	-20.36	↓	-20.74	↓	-9.72	↓	-10.08	↓
FBR+GLDM	91.35 (1.71)	42	68.24 (3.81)	56	80.79 (3.87)	37	56.50 (3.44)	145
GLDM	79.64(1.48)	-	50.59 (3.75)	-	64.24 (6.62)	-	38.74 (2.27)	-
ganho	11.71	↑	17.65	↑	16.55	↑	17.76	↑
FBR+Fourier	87.12 (2.59)	128	71.84 (3.68)	42	84.49 (2.93)	3	63.83 (3.17)	48
Fourier	85.32(2.40)	-	68.75 (2.76)	-	80.44 (3.60)	-	56.85 (3.23)	-
ganho	1.80	↑	3.09	↑	4.05	↑	6.98	↑
FBR+Gabor	93.06 (1.22)	27	74.78 (2.00)	18	90.62 (2.20)	40	76.83 (2.52)	4
Gabor	90.90(2.10)	-	72.06 (2.11)	-	88.43 (1.93)	-	70.59 (2.71)	-
ganho	2.16	↑	2.72	↑	2.20	↑	6.24	↑
FBR+Fractal	64.95 (4.94)	100	95.07 (2.83)	1	67.01 (3.11)	149	44.94 (3.08)	53
Fractal	57.30(4.06)	-	95.96 (3.93)	-	52.31 (5.80)	-	29.01 (3.12)	-
ganho	7.66	↑	-0.88	↓	14.70	↑	15.92	↑

Fonte: Elaborada pelo autor.

6.4 Difusão Anisotrópica Não Local

O parâmetro específico desse método é ε , utilizado na derivada fracional. Assim como os valores δ e p no método anterior, o valor de ε também foi sugerido pelo autor GUIDOTTI e recebeu o valor de 0.1. Seguindo a linha dos outros métodos, o valor máximo utilizado para iteração FOI 150 e $\lambda = 0.25$. Resultados são mostrados nas Tabelas 7, 25, 26, 27, 28 e 8.

Seguindo a mesma linha de resultados dos outros métodos de difusão, o LBP associado ao pré-processamento produziu os melhores resultados, enquanto para o Histograma e GLCM, os resultados foram negativos. Analisando todas as tabelas, o LBP com a difusão não local obteve taxa de 96.88% (Vistex), 96.76% (Brodatz), 83.53% (Outex) e 81.02% (UspTex).

Neste projeto, duas variáveis estão sendo analisadas. A primeira é a taxa de acerto máxima entre todas as analisadas e a segunda é o ganho máximo proporcionado pela utilização do método de pré-processamento. O GLDM, mais uma vez, foi o que mais se beneficiou com a adição da difusão. O maior ganho foi obtido na base Outex, com um incremento na taxa de acerto de 40.22% (Naive Bayes).

As Figuras 30, 31, 32 e 33 mostram todas as taxas de acerto para as 150 iterações resultantes da aplicação da difusão não local a imagem original em todos os descritores nas bases estudadas. Os resultados são similares em todas as bases analisadas com poucas diferenças

Tabela 6 – Resultados da aplicação da regularização forward-backward da difusão anisotrópica, são 150 iterações testas e a coluna melhor i apresenta a iteração que mostrou o melhor resultado. A tabela mostra os resultados para Naive Bayes.

	Naive Bayes							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
FBR+LBP	97.57 (1.80)	18	83.60 (3.63)	14	97.45 (1.20)	84	88.53 (2.47)	108
LBP	95.05(1.60)	-	80.81 (3.47)	-	95.49 (3.27)	-	78.71 (1.44)	-
ganho	2.52	↑	2.79	↑	1.97	↑	9.82	↑
FBR+Histogram	40.90 (4.65)	79	31.03 (1.95)	115	49.77 (3.22)	16	24.26 (1.65)	30
Histogram	44.77(4.31)	-	27.21 (2.45)	-	48.38 (4.32)	-	25.83 (1.38)	-
ganho	-3.87	↓	3.82	↑	1.39	↑	-1.57	↓
FBR+GLCM	79.28 (3.54)	119	57.57 (4.09)	43	69.44 (3.78)	2	41.45 (2.58)	140
GLCM	84.77(2.80)	-	62.35 (4.63)	-	73.03 (5.14)	-	47.86 (3.23)	-
ganho	-5.50	↓	-4.78	↓	-3.59	↓	-6.41	↓
FBR+GLDM	84.50 (2.81)	75	53.60 (3.30)	67	68.52 (5.50)	134	50.13 (3.66)	21
GLDM	60.99(4.48)	-	18.53 (1.92)	-	33.80 (4.03)	-	21.88 (1.55)	-
ganho	23.51	↑	35.07	↑	34.72	↑	28.25	↑
FBR+Fourier	83.78 (3.18)	65	67.21 (3.53)	31	80.79 (2.37)	1	61.30 (2.55)	26
Fourier	81.44(2.95)	-	56.62 (3.70)	-	71.99 (3.09)	-	48.43 (2.98)	-
ganho	2.34	↑	10.59	↑	8.80	↑	12.87	↑
FBR+Gabor	96.44 (2.72)	1	74.04 (4.22)	21	89.58 (3.14)	1	75.61 (3.83)	11
Gabor	95.41(3.02)	-	65.22 (2.48)	-	84.14 (3.40)	-	62.52 (2.85)	-
ganho	1.04	↑	8.82	↑	5.44	↑	13.09	↑
FBR+Fractal	48.11 (1.71)	147	36.47 (3.43)	108	45.89 (5.27)	16	29.67 (2.70)	114
Fractal	40.45(2.56)	-	20.15 (2.78)	-	32.81 (3.32)	-	15.36 (2.13)	-
ganho	7.66	↑	16.32	↑	13.08	↑	14.31	↑

Fonte: Elaborada pelo autor.

no descritor LBP aplicado na base transformada Outex, onde algumas iterações apresentam resultados negativos comparado a aplicação do método nas imagens originais. Nas outras bases, o LBP proposto potencializa o resultado e gera as maiores taxas de acerto. As imagens mostram que o GLCM e Histograma com o uso do método não enfatizou as características das imagens a ponto de aprimorar a extração de características desses métodos. Os métodos restantes foram todos positivamente afetados, como visto nas imagens referentes aos gráficos todas as bases.

Figura 30 – Taxas de acerto obtidas pela utilização da difusão anisotrópica não local aplicada às imagens originais. É mostrado a evolução para todos os descritores utilizando a base Vistex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 31 – Taxas de acerto obtidas pela utilização da difusão anisotrópica não local aplicada as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Brodatz e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 32 – Taxas de acerto obtidas pela utilização da difusão anisotrópica não local aplicada às imagens originais. É mostrado a evolução para todos os descritores utilizando a base Outex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 33 – Taxas de acerto obtidas pela utilização da difusão anisotrópica não local aplicada às imagens originais. É mostrado a evolução para todos os descritores utilizando a base Usptex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Tabela 7 – A tabela mostra os resultados da aplicação da difusão anisotrópica não local com os diferentes descritores e KNN, k = 1

	KNN, k = 1							
	Brodatz		Outex		Vistex		Usptex	
	melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>	
NL+LBP	96.76 (1.77)	124	75.15 (3.89)	119	95.60 (2.21)	130	77.84 (1.57)	140
LBP	93.96(1.70)	-	97.65 (2.48)	-	94.21 (2.74)	-	73.65 (2.47)	-
ganho	2.79	↑	-22.50	↓	1.39	↑	4.19	↑
NL+Histogram	23.60 (4.54)	115	22.57 (3.08)	71	32.29 (4.27)	145	12.61 (1.83)	30
Histogram	29.37(3.63)	-	25.15 (2.59)	-	36.00 (5.07)	-	13.05 (1.22)	-
ganho	-5.77	↓	-2.57	↓	-3.70	↓	-0.44	↓
NL+GLCM	72.52 (3.79)	145	57.50 (4.91)	40	80.79 (3.57)	44	56.24 (4.36)	1
GLCM	90.00(2.77)	-	72.72 (5.19)	-	87.38 (3.56)	-	63.74 (4.23)	-
ganho	-17.48	↓	-15.22	↓	-6.60	↓	-7.50	↓
NL+GLDM	90.63 (1.86)	65	69.26 (3.41)	1	80.79 (3.86)	5	56.94 (2.70)	2
GLDM	79.64(1.48)	-	50.59 (3.75)	-	64.24 (6.62)	-	38.74 (2.27)	-
ganho	10.99	↑	18.68	↑	16.55	↑	18.19	↑
NL+Fourier	86.67 (2.45)	19	72.13 (2.11)	90	84.84 (2.92)	107	64.79 (2.66)	150
Fourier	85.32(2.40)	-	68.75 (2.76)	-	80.44 (3.60)	-	56.85 (3.23)	-
ganho	1.35	↑	3.38	↑	4.40	↑	7.94	↑
NL+Gabor	92.70 (1.54)	30	75.29 (2.95)	93	90.62 (2.30)	115	77.27 (2.99)	150
Gabor	90.90(2.10)	-	72.06 (2.11)	-	88.43 (1.93)	-	70.59 (2.71)	-
ganho	1.80	↑	3.24	↑	2.20	↑	6.68	↑
NL+Fractal	61.08 (2.87)	101	43.82 (3.57)	26	60.42 (3.88)	79	37.74 (2.52)	107
Fractal	57.30(4.06)	-	48.46 (3.93)	-	52.31 (5.80)	-	29.01 (3.12)	-
ganho	3.78	↑	-4.63	↓	8.10	↑	8.73	↑

Fonte: Elaborada pelo autor.

6.5 Espaço de Escala gerado por Morfologia Matemática

Este é o único método no qual o número de iterações é pequeno. Nesta abordagem, só cinco iterações são geradas. No entanto, os resultados não são piores comparados aos outros métodos analisados. As imagens pré-processadas foram geradas pelo próprio autor do método com parâmetros $\sigma = 2.8$ para o núcleo gaussiano e $\rho = 0.1$. Os resultados são mostrados nas tabelas (Tabelas 9, 29, 30, 31, 32 e 10).

Apesar de conter apenas 5 iterações, ótimos resultados foram obtidos com essa metodologia. Somente alguns resultados negativos foram atingidos como pode ser observado nas tabelas. Porém, para o método Fractal, o uso do filtro morfológico gerou um benefício mínimo de 6.03% considerando todas as bases e todos os classificadores. Outro método grandemente beneficiado foi o GLDM, com ganho mínimo de 10.90% na taxa de acerto.

O GLCM e o Histograma, que obtiveram alguns resultados negativos para outros métodos de pré-processamento, alcançaram apenas ganhos positivos com esse método. O LBP foi o vencedor, utilizando o classificador Naive Bayes, onde na base Vistex atingiu 97.34% de reconhecimento nas classes quando o método puro resultava em 95.49%.

As Figuras 35, 34, 36,37 mostram o resultado do reconhecimento usando o classificador Naive Bayes para diferentes métodos de extração com e sem o pré-processamento associados para

Tabela 8 – A tabela mostra os resultados da aplicação da difusão anisotrópica não local com os diferentes descritores e Naive Bayes

	Naive Bayes							
	Brodatz		Outex		Vistex		Usptex	
	melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>	
NL+LBP	96.31 (1.63)	140	83.53 (3.59)	149	96.88 (3.08)	77	81.02 (1.47)	129
LBP	95.05(1.60)	-	80.81 (3.47)	-	95.49 (3.27)	-	78.71 (1.44)	-
ganho	1.26	↑	2.72	↑	1.39	↑	2.31	↑
NL+Histogram	39.28 (3.85)	111	26.54 (2.00)	1	43.63 (3.78)	102	22.51 (2.08)	49
Histogram	44.77(4.31)	-	27.21 (2.45)	-	48.38 (4.32)	-	25.83 (1.38)	-
ganho	-5.50	↓	-0.66	↓	-4.75	↓	-3.32	↓
NL+GLCM	70.90 (2.56)	140	57.21 (3.58)	148	69.68 (4.22)	79	41.67 (3.50)	51
GLCM	84.77(2.80)	-	62.35 (4.63)	-	73.03 (5.14)	-	47.86 (3.23)	-
ganho	-13.87	↓	-5.15	↓	-3.36	↓	-6.20	↓
NL+GLDM	83.96 (2.54)	23	58.75 (3.64)	1	67.01 (5.07)	6	52.62 (2.94)	1
GLDM	60.99(4.48)	-	18.53 (1.92)	-	33.80 (4.03)	-	19.85 (1.55)	-
ganho	22.97	↑	40.22	↑	33.22	↑	32.77	↑
NL+Fourier	83.33 (3.66)	5	68.75 (2.47)	92	80.67 (2.54)	3	61.39 (2.56)	100
Fourier	81.44(2.95)	-	60.55 (3.70)	-	71.99 (3.09)	-	48.43 (2.98)	-
ganho	1.89	↑	8.20	↑	8.68	↑	12.96	↑
NL+Gabor	90.63 (2.73)	50	75.51 (3.72)	48	89.58 (3.14)	1	76.31 (3.27)	49
Gabor	89.10(3.02)	-	65.22 (2.48)	-	84.14 (3.40)	-	62.52 (2.85)	-
ganho	1.53	↑	10.29	↑	5.44	↑	13.79	↑
NL+Fractal	45.68 (1.70)	141	32.21 (4.66)	1	43.52 (3.92)	119	27.62 (1.75)	146
Fractal	40.45(2.56)	-	20.15 (2.78)	-	31.37 (3.32)	-	15.36 (2.13)	-
ganho	5.23	↑	12.06	↑	12.15	↑	12.26	↑

Fonte: Elaborada pelo autor.

meios de comparação em todas as bases. É possível perceber, mesmo com poucas iterações que o uso da difusão morfológica aperfeiçoa a extração de características na maioria dos descritores analisados. Nas bases Outex e Usptex os resultados são sempre positivos para a proposta, considerando todos os descritores. Já na base Brodatz, as imagens transformadas pela difusão morfológica não melhoram os resultados dos descritores Gabor e Fourier. Por fim, na base Vistex o uso da quinta iteração não aperfeiçoou a extração de características do algoritmo Gabor.

Figura 34 – Taxas de acerto obtida pela utilização do filtro de choque aplicados as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Vistex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 35 – Taxas de acerto obtida pela utilização do filtro de choque aplicados as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Brodatz e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 36 – Taxas de acerto obtida pela utilização do filtro de choque aplicados as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Outex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 37 – Taxas de acerto obtida pela utilização do filtro de choque aplicados as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Usptex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Tabela 9 – Resultados da aplicação do filtro morfológico nas imagens dos quatro banco de dados com a análise de diferentes descritores e classificador KNN (k = 1).

	KNN, k = 1							
	Brodatz		Outex		Vistex		Usptex	
	melhor <i>i</i>		melhor <i>i</i>		best <i>i</i>		melhor <i>i</i>	
SF+LBP	96.13 (1.42)	1	75.51 (3.20)	4	96.41 (1.91)	2	79.10 (1.62)	4
LBP	93.96(1.70)	-	72.50 (2.48)	-	94.21 (2.74)	-	73.65 (2.47)	-
ganho	2.16	↑	3.01	↑	2.20	↑	5.45	↑
SF+Histogram	11.35 (1.48)	1	30.00 (3.70)	5	26.16 (3.68)	1	12.87 (2.43)	1
Histogram	29.37(3.63)	-	25.15 (2.59)	-	36.00 (5.07)	-	13.05 (1.22)	-
ganho	-18.02	↓	4.85	↑	-9.84	↓	-0.17	↓
SF+GLCM	92.79 (1.95)	5	77.35 (2.69)	5	89.12 (1.47)	2	74.65 (2.57)	5
GLCM	90.00(2.77)	-	72.72 (5.19)	-	87.38 (3.56)	-	63.74 (4.23)	-
ganho	2.79	↑	4.63	↑	1.74	↑	10.91	↑
SF+GLDM	90.90 (2.49)	1	71.76 (2.73)	1	81.94 (2.11)	1	55.45 (2.39)	1
GLDM	79.64(1.48)	-	50.59 (3.75)	-	64.24 (6.62)	-	38.74 (2.27)	-
ganho	11.26	↑	21.18	↑	17.71	↑	16.71	↑
SF+Fourier	86.04 (2.09)	1	70.37 (2.64)	1	81.60 (4.13)	3	61.56 (3.15)	1
Fourier	85.32(2.40)	-	68.75 (2.76)	-	80.44 (3.60)	-	56.85 (3.23)	-
ganho	0.72	↑	1.62	↑	1.16	↑	4.71	↑
SF+Gabor	91.26 (1.84)	4	71.84 (2.35)	3	87.04 (1.41)	1	72.03 (4.27)	1
Gabor	90.90(2.10)	-	72.06 (2.11)	-	88.43 (1.93)	-	70.59 (2.71)	-
ganho	0.36	↑	-0.22	↓	-1.39	↓	1.44	↑
SF+Fractal	76.31 (2.79)	1	54.49 (5.46)	4	68.75 (3.27)	1	46.20 (3.07)	5
Fractal	57.30(4.06)	-	48.46 (3.93)	-	52.31 (5.80)	-	29.01 (3.12)	-
ganho	19.01	↑	6.03	↑	16.44	↑	17.19	↑

Fonte: Elaborada pelo autor.

6.6 Transformada de Distância Euclidiana

Como dito anteriormente, aplicado a imagens em níveis de cinza, a transformada retorna um cubo de tamanho $M \times N \times T$, onde T é o número de iterações máximo aqui atribuído como 150. Cada fatia (eixo z) desse cubo é entendida como uma imagem e analisada como uma iteração i . Os resultados são mostrados nas Tabelas 11, 33, 34, 35, 36 e 12.

Analisando as tabelas, os melhores resultados são obtidos com KNN para $k = 1$ e Naive Bayes. Mais uma vez o GLDM obteve melhor aproveitamento das imagens derivadas enquanto o LBP obteve maior taxa de acerto absoluto. Os resultados para o LBP utilizando a EDT são: 96.94% para Brodatz, 85.88% para Outex, 96.64% para Vistex e 82.24% para Usptex (classificador Naive Bayes).

A EDT teve uma grande influência em todos os métodos de extração com exceção dos métodos: descritor de Fourier, nas bases Usptex, Brodatz e Vistex, e Gabor, nas bases Usptex e Brodatz. Para o descritor Fractal, o método teve um ganho e 22.94% passando de 20.15% para 43.08% (base Outex). O método Histograma combinado com o pré-processamento, incrementou em 14.23% a taxa de acerto da Brodatz.

As Figuras 38, 39, 40 e 41 mostram os resultados obtidos para diferentes extratores e bases comparando os resultados dos métodos originais e dos métodos propostos. A EDT é o método que apresenta os gráficos com maior oscilação na taxa de acerto e maior variação da

Tabela 10 – Resultados da aplicação do filtro morfológico nas imagens dos quatro banco de dados com a análise de diferentes descritores e classificador Naive Bayes.

	Naive Bayes							
	Brodatz		Outex		Vistex		Usptex	
	melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>	
SF+LBP	96.22 (1.86)	2	83.46 (2.52)	5	97.34 (2.36)	3	86.78 (2.01)	3
LBP	95.05(1.60)	-	80.81 (3.47)	-	95.49 (3.27)	-	78.71 (1.44)	-
ganho	1.17	↑	2.65	↑	1.85	↑	8.07	↑
SF+Histogram	56.67 (6.56)	5	40.37 (2.99)	5	55.79 (4.50)	3	35.38 (2.83)	2
Histogram	44.77(4.31)	-	27.21 (2.45)	-	48.38 (4.32)	-	25.83 (1.38)	-
ganho	11.89	↑	13.16	↑	7.41	↑	9.55	↑
SF+GLCM	88.38 (1.99)	5	73.75 (3.50)	5	81.71 (4.91)	4	63.09 (2.36)	5
GLCM	84.77(2.80)	-	62.35 (4.63)	-	73.03 (5.14)	-	47.86 (3.23)	-
ganho	3.60	↑	11.40	↑	8.68	↑	15.23	↑
SF+GLDM	81.71 (2.44)	1	61.69 (3.35)	5	67.48 (5.64)	1	51.92 (3.76)	1
GLDM	60.99(4.48)	-	18.53 (1.92)	-	33.80 (4.03)	-	19.85 (1.55)	-
ganho	20.72	↑	43.16	↑	33.68	↑	32.07	↑
SF+Fourier	81.17 (2.58)	1	63.53 (2.86)	2	75.69 (2.60)	1	54.54 (2.06)	5
Fourier	81.44(2.95)	-	56.62 (3.70)	-	71.99 (3.09)	-	48.43 (2.98)	-
ganho	-0.27	↓	6.91	↑	3.70	↑	6.11	↑
SF+Gabor	89.01 (2.18)	2	70.22 (2.51)	5	84.84 (3.20)	1	67.54 (2.95)	1
Gabor	89.10(3.02)	-	65.22 (2.48)	-	84.14 (3.40)	-	62.52 (2.85)	-
ganho	-0.09	↓	5.00	↑	0.69	↑	5.02	↑
SF+Fractal	56.49 (3.63)	4	39.63 (4.29)	5	43.63 (4.14)	3	29.76 (2.72)	5
Fractal	40.45(2.56)	-	20.15 (2.78)	-	31.37 (3.32)	-	15.36 (2.13)	-
ganho	16.04	↑	19.49	↑	12.27	↑	14.40	↑

Fonte: Elaborada pelo autor.

influência do método de pré-processamento nas diferentes bases.

Para a base Vistex (Figura 38), nos métodos Histograma, GLCM, GLDM, Fourier e Fractal, a maior parte, ou a totalidade, das iterações eleva a taxa de sucesso em relação ao método original. Já no caso do LBP, a taxa de acerto proposta flutua ao redor do resultado do método aplicado nas imagens originais da base. Apesar disto, o algoritmo de difusão associado ao LBP ainda atinge a maior taxa de acerto, 96.64%, na base Vistex quando é utilizada a iteração 18.

Para a base Brodatz, Figura 39, o único método no qual todas as iterações apresentam incremento na taxa de acerto original é o uso da EDT + Gabor. Para outros métodos, a maior parte das iterações aprimora o resultado dos descritores, mas não a totalidade. Na maioria dos gráficos, as iterações iniciais mostram resultados mais baixos e com o incremento das iterações essa taxa de acerto se eleva.

O resultado das imagens da base Outex transformadas pela EDT são mostradas na Figura 40. Para os descritores Fractal, Fourier, GLDM e Histograma, a proposta otimiza os métodos em todas as iterações avaliadas. No extrator de Gabor, poucas iterações não superam o método original. No entanto, para o LBP e GLCM, o gráfico se mostra menos linear. No GLCM, um pico na taxa de acerto ocorre entre as iterações 25 e 88. Já no LBP, o resultado é positivo até a iteração 110, caindo logo após.

Por fim a base Usptex, mostrada na Figura 41, associada ao método de pré-processamento

analisado nesta seção potencializa o resultado dos descritores Fractal, GLDM e Histograma. Os gráficos em azul dos descritores Fourier e Gabor são bem parecidos, os resultados das iterações crescem até certo ponto e depois começam a decrescer. Para o LBP e GLCM, os gráficos mostram uma grande variação nas taxas de acerto gerando um gráfico oscilante apesar da maioria dos resultados superarem a abordagem tradicional.

Figura 38 – Taxas de acerto obtida pela utilização da EDT aplicadas as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Vistex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 39 – Taxas de acerto obtida pela utilização da EDT aplicadas as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Brodatz e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 40 – Taxas de acerto obtida pela utilização da EDT aplicadas as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Outex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Figura 41 – Taxas de acerto obtida pela utilização da EDT aplicadas as imagens originais. É mostrado a evolução para todos os descritores utilizando a base Usptex e classificador Naive Bayes. As retas vermelhas representam a extração das características sem nenhum uso de pré-processamento.

Fonte: Elaborada pelo autor.

Tabela 11 – São apresentadas as taxas de sucesso com KNN, $k = 1$ a partir das imagens transformadas e não transformadas pelo método EDT.

	KNN, k=1							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
EDT+LBP	96.94 (1.44)	147	83.24 (3.59)	50	96.06 (3.40)	112	80.10 (2.68)	75
LBP	93.96(1.70)	-	72.50 (2.48)	-	94.21 (2.74)	-	73.65 (2.47)	-
ganho	2.97	↑	10.74	↑	1.85	↑	6.46	↑
EDT+Histogram	39.01 (3.51)	111	39.12 (3.47)	66	45.60 (4.70)	92	18.85 (1.95)	137
Histogram	29.37(3.63)	-	25.15 (2.59)	-	36.00 (5.07)	-	13.05 (1.22)	-
ganho	9.64	↑	13.97	↑	9.61	↑	5.80	↑
EDT+GLCM	93.06 (1.82)	77	76.10 (3.21)	65	90.16 (2.71)	133	67.58 (2.99)	144
GLCM	90.00(2.77)	-	72.72 (5.19)	-	87.38 (3.56)	-	63.74 (4.23)	-
ganho	3.06	↑	3.38	↑	2.78	↑	3.84	↑
EDT+GLDM	79.19 (3.33)	78	62.94 (3.12)	42	68.98 (4.82)	37	40.62 (2.61)	67
GLDM	79.64(1.48)	-	50.59 (3.75)	-	64.24 (6.62)	-	38.74 (2.27)	-
ganho	-0.45	↓	12.35	↑	4.75	↑	1.88	↑
EDT+Fourier	85.23 (3.48)	93	70.59 (2.67)	63	74.88 (5.22)	73	50.35 (3.00)	131
Fourier	85.32(2.40)	-	68.75 (2.76)	-	80.44 (3.60)	-	56.85 (3.23)	-
ganho	-0.09	↓	1.84	↑	-5.56	↓	-6.50	↓
EDT+Gabor	90.54 (2.65)	78	78.38 (2.54)	52	87.96 (4.97)	56	65.45 (2.68)	134
Gabor	90.90(2.10)	-	72.06 (2.11)	-	88.43 (1.93)	-	70.59 (2.71)	-
ganho	-0.36	↓	6.32	↑	-0.46	↓	-5.15	↓
EDT+Fractal	55.41 (2.79)	74	53.68 (3.50)	43	49.65 (5.74)	63	28.10 (1.91)	100
Fractal	57.30(4.06)	-	48.46 (3.93)	-	52.31 (5.80)	-	29.01 (3.12)	-
ganho	-1.89	↓	5.22	↑	-2.66	↓	-0.92	↓

Fonte: Elaborada pelo autor.

6.7 Discussão dos Resultados

Este capítulo apresentou os resultados obtidos nos experimentos com uso de métodos de pré-processamento em comparação ao uso de métodos de extração de características aplicados nos dados originais. Dada a quantidade de resultados mostrados, uma análise é necessária para avaliar três pontos principais:

- O uso de imagens em uma escala diferente da original incrementa o reconhecimento de texturas?
- Os métodos são dependentes da base de dados?
- Os métodos são dependentes do método de extração de características?

De maneira geral, é possível perceber que a adição da imagens transformadas influenciou positivamente a extração de características. No entanto, é necessário separar a análise em vários quesitos. Os métodos de pré-processamento, por exemplo, como pode ser notado pelas tabelas de resultado, funcionam diferente de acordo com o método de análise de textura utilizado.

O primeiro método, a **difusão isotrópica**, onde a imagem original é convolvida com uma Gaussiana e a cada iteração, o valor do σ é incrementado apresentou um aumento na taxa de acerto em todas as bases testadas e para todos os descritores utilizados. Apenas no método

Tabela 12 – São apresentadas as taxas de sucesso com Naive Bayes a partir das imagens transformadas e não transformadas pelo método EDT.

	Naive Bayes							
	Brodatz		Outex		Vistex		Usptex	
	melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>	
EDT+LBP	96.94 (2.17)	149	85.88 (3.18)	47	96.64 (2.56)	18	82.24 (2.67)	70
LBP	95.05(1.60)	-	80.81 (3.47)	-	95.49 (3.27)	-	78.71 (1.44)	-
ganho	1.89	↑	5.07	↑	1.16	↑	3.53	↑
EDT+Histogram	41.89 (5.41)	125	46.84 (4.32)	55	56.13 (3.90)	96	32.77 (3.04)	132
Histogram	27.66(4.31)	-	27.21 (2.45)	-	48.38 (4.32)	-	25.83 (1.38)	-
ganho	14.23	↑	19.63	↑	7.75	↑	6.94	↑
EDT+GLCM	89.10 (2.27)	146	72.35 (4.30)	66	79.63 (3.96)	50	53.10 (4.17)	15
GLCM	84.77(2.80)	-	62.35 (4.63)	-	73.03 (5.14)	-	47.86 (3.23)	-
ganho	4.32	↑	10.00	↑	6.60	↑	5.24	↑
EDT+GLDM	75.59 (3.79)	73	50.29 (4.37)	47	51.62 (4.34)	26	41.14 (2.17)	82
GLDM	59.46(4.48)	-	18.53 (1.92)	-	33.80 (4.03)	-	23.21 (1.55)	-
ganho	16.13	↑	31.76	↑	17.82	↑	17.93	↑
EDT+Fourier	91.17 (2.91)	101	69.04 (3.07)	49	77.43 (3.60)	19	54.49 (3.06)	126
Fourier	91.49(2.95)	-	56.62 (3.70)	-	71.99 (3.09)	-	48.43 (2.98)	-
ganho	-0.32	↓	12.43	↑	5.44	↑	6.06	↑
EDT + Gabor	91.71	21	78.16	47	86.92	58	65.22	101
Gabor	89.09	-	65.22	-	84.14	-	62.52	-
ganho	2.62	↑	12.94	↑	2.78	↑	2.70	↑
EDT+Fractal	53.15 (6.05)	75	43.09 (6.09)	43	44.79 (3.43)	15	24.69 (2.87)	87
Fractal	40.45(2.56)	-	20.15 (2.78)	-	31.37 (3.32)	-	15.36 (2.13)	-
ganho	12.70	↑	22.94	↑	13.43	↑	9.34	↑

Fonte: Elaborada pelo autor.

de primeira ordem, Histograma, na base Vistex com KNN, $k=1$, o método proposto não obteve incremento na taxa de acerto.

O **método de difusão anisotrópico clássico** não favorece os métodos GLCM e Histograma. Porém para os outros métodos descritores, o pré-processamento ajudou a melhor extrair características favorecendo o reconhecimento de padrões. O classificador Naive Bayes e o KNN, $k=1$, ofereceram os melhores resultados em termos de ganho e taxa de acerto absoluto e o GLDM foi o método mais beneficiado com o uso das imagens transformadas.

Os **dois métodos de regularização da difusão anisotrópica** funcionaram da mesma maneira que o clássico, auxiliando os descritores Fractal, LBP, GLDM, Fourier e Gabor e Fractal, mas não favorecendo o GLCM e Histograma. Comparando os três métodos e todos os resultados, as bases Brodatz, Usptex e Vistex foram melhor enfatizadas com a utilização dos métodos FBR e PM, enquanto a Outex se saiu melhor com o uso dos algoritmos NL e FBR.

O **filtro de choque** surpreendeu por seu bom resultado com poucas iterações. Com ganhos de até 8.07% para a base Usptex, no método LBP (o mais difícil de ser incrementado), o método se mostrou excelente intensificador de características principalmente para os métodos GLCM (até 15%), GLDM (até 43%) e Fractal (até 20%).

O último método, a **EDT**, que não é usualmente utilizada como método gerador de diferentes escalas, mas pode ser utilizado desta forma como mostrado no Capítulo 4, é o que apresenta os gráficos com resultados mais oscilantes. O método influenciou positivamente a

extração de características dos descritores GLDM e Fractal, sendo melhor utilizado quando associação ao classificador Naive Bayes.

Além disso, é possível analisar o desempenho das combinações em relação ao classificador utilizado. Os classificadores que apresentaram o melhor desempenho foram o KNN ($k = 1$) e o Naive Bayes. Essa informação foi obtida ordenando todos os ganhos e taxas de acerto de maneira decrescente e sempre observando qual classificador obtinha as maiores taxas. Apesar de muito famoso na Computação, o artigo (AMANCIO *et al.*, 2014) mostrou que o classificador SVM, descrito no Capítulo 3, pode não superar a taxa de acerto em comparação a outros classificadores mais simples (assim como o KNN e Naive Bayes aqui utilizados). Além disso, o SVM adiciona um custo computacional maior aos métodos, caso verificado em alguns experimentos preliminares, o que o tornaria desnecessário (pelos motivos acima) para a aplicação.

As Figuras, 42, 43, 44 e 45 mostram um gráfico de barras para comparação dos resultados obtidos pelo classificador Naive Bayes entre todos os métodos de pré-processamento associado aos descritores e o uso dos descritores nas imagens originais. Já os Gráficos 46, 47, 48 e 49, apresentam os resultados para o classificador KNN ($k = 1$). A barra em vermelho representa o uso do descritor original enquanto as outras cores apresentam o método aplicado nas imagens transformadas. É possível perceber a alta taxa de acerto obtida pelo descritor LBP principalmente para o classificador Naive Bayes. Já nos resultados com KNN ($k = 1$), o LBP ainda é o melhor descritor exceto para base Outex, onde o GLDM + G supera todos os resultados.

Neste trabalho, duas medidas devem ser comparadas: taxa de acerto absoluto e ganho em relação ao método de extração aplicado à base de dados original. Como mencionado anteriormente, para todos os métodos, exceto para base Outex, a maior taxa de acerto é obtida pelo uso do descritor LBP. Nas bases Brodatz e Usptex, a FBR associada a este descritor supera o método original, se tornando a maior taxa de reconhecimento (Naive Bayes). Já para a Vistex, o melhor resultado é alcançado quando o método de difusão clássico, PM, é associado ao descritor local (KNN, $k = 3$). Por fim, diferente das outras bases, a melhor taxa de reconhecimento de texturas para a base Outex foi obtida com o uso da Gaussiana associada ao GLDM (KNN, $k = 1$).

Um fator importante a se evidenciar é o uso do extrator Fractal neste projeto. Para execução dos experimentos, os métodos de classificação escolhidos foram o KNN e Naive Bayes por apresentarem bons resultados e simplicidade. No entanto, é conhecido que o fractal apresenta melhores resultados com a utilização do LDA (Análise Discriminante Linear) pois o método encontra uma combinação linear das características do fractal capaz de separar melhor as classes (FLORINDO; CASTRO; BRUNO, 2010).

Em geral, todos os métodos foram benéficos para a classificação das bases. Na base Usptex, o ganho foi surpreendente, atingindo 88.52% (FBR + LBP, Naive Bayes), uma boa taxa de acerto para a base tão diversificada e com uma grande quantidade de classes e imagens. A base Outex possui imagens de diferentes classes que são muito semelhantes e por isso a classificação se torna difícil. No entanto, os métodos de pré-processamento foram úteis para aumentar a

taxa de reconhecimento dessa base. A Vistex foi a base que obteve a taxa de acerto mais alta dentre as avaliadas. Exceto pelos descritores GLCM e Histograma, o uso da combinação de pré-processamento com os descritores influenciou a taxa de acerto positivamente considerando todos as transformações.

Analisando não as bases nem as transformações, mas os descritores, nota-se não ser necessário utilizar as imagens em diferentes escalas com os métodos GLCM e o descritor de primeira ordem, Histograma. Nos dois casos apenas a Gaussiana e a EDT foram beneficiadas e para o GLCM, em algumas bases, o filtro de choque também foi vantajoso. A combinação EDT + Gabor e EDT + Fourier foram vantajosas para as bases Vistex e Usptex mas não para as outras bases.

Figura 42 – Comparação entre todos os resultados obtidos pelo classificador Naive Bayes para a base Brodatz.

Fonte: Elaborada pelo autor.

Figura 43 – Comparação entre todos os resultados obtidos pelo classificador Naive Bayes para a base Outex.

Fonte: Elaborada pelo autor.

Figura 44 – Comparação entre todos os resultados obtidos pelo classificador Naive Bayes para a base Vistex.

Fonte: Elaborada pelo autor.

Figura 45 – Comparação entre todos os resultados obtidos pelo classificador Naive Bayes para a base Usptex.

Fonte: Elaborada pelo autor.

Figura 46 – Comparação entre todos os resultados obtidos pelo classificador KNN (k = 1) para a base Brodatz.

Fonte: Elaborada pelo autor.

Figura 47 – Comparação entre todos os resultados obtidos pelo classificador KNN ($k = 1$) para a base Outex.

Fonte: Elaborada pelo autor.

Figura 48 – Comparação entre todos os resultados obtidos pelo classificador KNN ($k = 1$) para a base Vistex.

Fonte: Elaborada pelo autor.

Figura 49 – Comparação entre todos os resultados obtidos pelo classificador KNN ($k = 1$) para a base Usptex.

Fonte: Elaborada pelo autor.

CONCLUSÕES

O uso de textura para reconhecimento de padrões em imagens é um constante objeto de estudo de muitos pesquisadores na área de visão computacional. Durante vários anos de pesquisa, o foco vem sendo criar metodologias que melhor extraiam características dessas texturas a fim de segmentá-las, classificá-las e sintetizá-las. Foram descritos nesse projeto, diversos métodos de análise de textura muito utilizados na literatura como LBP, Gabor, Histograma, Fractal, entre outros descritores apresentados no Capítulo 2.

Tentando aprimorar esses métodos já existentes e muito estudados, este projeto tem como objeto não criar um método de extração novo, mas transformar as imagens de entrada para que os descritores consigam extrair melhor as características peculiares de cada tipo de textura. O projeto propõe a aplicação de seis métodos de caráter multi-escala: 5 métodos de difusão e a transformada de distância.

Um dos objetivos do trabalho foi analisar a influência dos métodos de pré-processamentos na extração de características e consequente classificação de texturas. Dado os resultados obtidos, é possível perceber uma dificuldade em dizer qual método de pré-processamento é melhor. Essa análise é muito dependente da base de dados analisada, da combinação (pré-processamento + extrator) e ainda do classificador. Além disso, duas métricas são apresentadas: taxa de acerto absoluta e ganho em relação a abordagem clássica (descritores aplicados à base de dados original). Em relação a taxa de acerto da classificação, o LBP obteve uma maior taxa de acerto associada à difusão anisotrópica clássica na Vistex (98.84%), à regularização forward-backward da difusão anisotrópica na Brodatz (97.57%) e Usptex (88.52%). Apenas a base Outex não apresentou melhor resultado com esse descritor. Neste caso, o maior resultado, 97.79%, foi obtido com o extrator GLDM com a base transformada por uma Gaussiana.

A segunda medida analisada é o ganho relativo da proposta em relação ao método original. O uso de difusão isotrópica foi a que mais influenciou positivamente um método de análise de textura. O GLDM foi potencializado na extração de características de todas as bases

aqui estudadas porém não foi o método que obteve maior resultado absoluto (exceto para a base Outex).

Neste trabalho, apenas a combinação de uma escala associada à base original foi utilizada. No entanto, pode-se desenvolver metodologias utilizando mais de uma escala para composição do conjunto de entrada para os métodos descritores. Esse agregado de informações pode ser útil para descrição das texturas. Além disso, pode-se utilizar outros métodos de pré-processamento incluindo aqueles que levam em consideração a informação de cor da imagem já que aqui todas são transformadas em escala de cinza.

O projeto mostra um resultado favorável e encorajador para a utilização de imagens transformadas para o auxílio da extração de características. Apesar de uma fase de treino um pouco custosa pois todas as iteração são avaliadas (apesar da geração das imagens em diferentes escalas serem produzidas rapidamente), o benefício do ganho da taxa de reconhecimento de texturas é vantajoso. Além disso, após o treino, apenas uma iteração será necessária para posterior classificação.

REFERÊNCIAS

AMANCIO, D. R.; COMIN, C. H.; CASANOVA, D.; TRAVIESO, G.; BRUNO, O. M.; RODRIGUES, F. A.; COSTA, L. da F. A systematic comparison of supervised classifiers. **PloS one**, Public Library of Science, v. 9, n. 4, p. e94137, 2014. Citado na página 109.

ANITHA, S.; RADHA, V. Comparison of image preprocessing techniques for textile texture images. **International Journal of Engineering Science and Technology**, v. 2, n. 12, p. 7619–7625, 2010. Citado 2 vezes nas páginas 30 e 50.

BACKES, A. R.; BRUNO, O. M. Plant leaf identification using multi-scale fractal dimension. In: **Image Analysis and Processing–ICIAP 2009**. [S.l.]: Springer, 2009. p. 143–150. Citado 3 vezes nas páginas 29, 33 e 63.

BRODATZ, P. **Textures: a photographic album for artists and designers**. [S.l.]: Dover New York, 1966. Citado na página 65.

BRUNO, O. M.; PLOTZE, R. de O.; FALVO, M.; CASTRO, M. de. Fractal dimension applied to plant identification. **Information Sciences**, Elsevier, v. 178, n. 12, p. 2722–2733, 2008. Citado na página 61.

CAMPBELL, C. An introduction to kernel methods. **Studies in Fuzziness and Soft Computing**, PHYSICA-VERLAG, v. 66, p. 155–192, 2001. Citado na página 45.

CANNY, J. A computational approach to edge detection. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, IEEE, n. 6, p. 679–698, 1986. Citado na página 54.

CHIN, Y. T.; WANG, H.; TAY, L. P.; WANG, H.; SOH, W. Y. Vision guided agv using distance transform. In: CITESEER. **Proceedings of the 32nd ISR (International Symposium on Robotics)**. [S.l.], 2001. v. 19, p. 21. Citado na página 58.

COBURN, C.; ROBERTS, A. C. A multiscale texture analysis procedure for improved forest stand classification. **International journal of remote sensing**, Taylor & Francis, v. 25, n. 20, p. 4287–4308, 2004. Citado na página 63.

COSGRIFF, R. Identification of shape. **Ohio State University Research Foundation, Columbus, Rep**, p. 820–11, 1960. Citado na página 40.

COSTA, L. d. F. D.; JR, R. M. C. **Shape analysis and classification: theory and practice**. [S.l.]: CRC Press, Inc., 2000. Citado na página 41.

DORINI, L. B.; LEITE, N. J. Teoria espaço-escala: abordagem morfológica. **Revista de Informática Teórica e Aplicada**, UFGRS, v. 17, n. 1, p. 115–136, 2010. Citado 2 vezes nas páginas 51 e 52.

FLORINDO, J. B.; BRUNO, O. M. Texture analysis by multi-resolution fractal descriptors. **Expert Systems with Applications**, Elsevier, v. 40, n. 10, p. 4022–4028, 2013. Citado 2 vezes nas páginas 30 e 63.

- FLORINDO, J. B.; CASTRO, M. D.; BRUNO, O. M. Enhancing multiscale fractal descriptors using functional data analysis. **International Journal of Bifurcation and Chaos**, World Scientific, v. 20, n. 11, p. 3443–3460, 2010. Citado na página 109.
- FOURIER, J. B. J. baron. **The analytical theory of heat**. [S.l.]: The University Press, 1878. Citado na página 40.
- GALLOWAY, M. M. Texture analysis using gray level run lengths. **Computer graphics and image processing**, Elsevier, v. 4, n. 2, p. 172–179, 1975. Citado na página 30.
- GLATARD, T.; MONTAGNAT, J.; MAGNIN, I. E. Texture based medical image indexing and retrieval: application to cardiac imaging. In: ACM. **Proceedings of the 6th ACM SIGMM international workshop on Multimedia information retrieval**. [S.l.], 2004. p. 135–142. Citado 2 vezes nas páginas 29 e 30.
- GONZALEZ, R. C. **Digital image processing**. [S.l.]: Pearson Education India, 2009. Citado na página 33.
- GROSS, R.; BRAJOVIC, V. An image preprocessing algorithm for illumination invariant face recognition. In: SPRINGER. **Audio-and Video-Based Biometric Person Authentication**. [S.l.], 2003. p. 10–18. Citado na página 49.
- GUIDOTTI, P. A new nonlocal nonlinear diffusion of image processing. **Journal of Differential Equations**, Elsevier, v. 246, n. 12, p. 4731–4742, 2009. Citado 3 vezes nas páginas 55, 56 e 88.
- _____. A backward–forward regularization of the perona–malik equation. **Journal of Differential Equations**, Elsevier, v. 252, n. 4, p. 3226–3244, 2012. Citado na página 55.
- GUIDOTTI, P.; KIM, Y.; LAMBERS, J. Image restoration with a new class of forward-backward-forward diffusion equations of perona–malik type with applications to satellite image enhancement. **SIAM Journal on Imaging Sciences**, SIAM, v. 6, n. 3, p. 1416–1444, 2013. Citado 2 vezes nas páginas 54 e 55.
- GUPTA, M. R.; JACOBSON, N. P.; GARCIA, E. K. Ocr binarization and image pre-processing for searching historical documents. **Pattern Recognition**, Elsevier, v. 40, n. 2, p. 389–397, 2007. Citado na página 49.
- GUPTA, R.; UNDRILL, P. The use of texture analysis to delineate suspicious masses in mammography. **Physics in Medicine and Biology**, IOP Publishing, v. 40, n. 5, p. 835, 1995. Citado na página 50.
- HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The weka data mining software: an update. **ACM SIGKDD explorations newsletter**, ACM, v. 11, n. 1, p. 10–18, 2009. Citado 2 vezes nas páginas 47 e 66.
- HARALICK, R. M. Statistical and structural approaches to texture. **Proceedings of the IEEE**, IEEE, v. 67, n. 5, p. 786–804, 1979. Citado na página 37.
- HEASRT, M.; SCHOLKOPF, B.; DUMAIS, S.; OSUNA, E.; PLATT, J. Trends and controversies-support vector machines. **IEEE Intelligent Systems**, v. 13, n. 4, p. 18–28, 1998. Citado na página 45.

- HEUSCH, G.; RODRIGUEZ, Y.; MARCEL, S. Local binary patterns as an image preprocessing for face authentication. In: IEEE. **Automatic Face and Gesture Recognition, 2006. FGR 2006. 7th International Conference on**. [S.l.], 2006. p. 6–pp. Citado na página 49.
- HSU, H. P. **Análise de Fourier**. [S.l.]: Livros Técnicos e Científicos, 1973. Citado na página 40.
- IDRISSA, M.; ACHEROY, M. Texture classification using gabor filters. **Pattern Recognition Letters**, Elsevier, v. 23, n. 9, p. 1095–1102, 2002. Citado na página 39.
- JONES, M.; BAERENTZEN, J. A.; SRAMEK, M. 3d distance fields: A survey of techniques and applications. **Visualization and Computer Graphics, IEEE Transactions on**, IEEE, v. 12, n. 4, p. 581–599, 2006. Citado na página 59.
- JULESZ, B. Experiments in the visual perception of texture. **Scientific American**, n. 4, p. 34–43, 1975. Citado 2 vezes nas páginas 34 e 36.
- JUNIOR, C.; MARCONDES, R. **Análise multi-escala de formas bidimensionais**. Tese (Doutorado) — Universidade de São Paulo, 1997. Citado na página 51.
- KAPLAN, L. M. Extended fractal analysis for texture classification and segmentation. **Image Processing, IEEE Transactions on**, IEEE, v. 8, n. 11, p. 1572–1585, 1999. Citado na página 41.
- KASS, M.; SOLOMON, J. Smoothed local histogram filters. In: ACM. **ACM Transactions on Graphics (TOG)**. [S.l.], 2010. v. 29, n. 4, p. 100. Citado na página 57.
- KICHENASSAMY, S. The perona–malik paradox. **SIAM Journal on Applied Mathematics**, SIAM, v. 57, n. 5, p. 1328–1342, 1997. Citado na página 55.
- KOENDERINK, J. J. The structure of images. **Biological cybernetics**, Springer, v. 50, n. 5, p. 363–370, 1984. Citado 3 vezes nas páginas 50, 51 e 52.
- KONG, W. K.; ZHANG, D.; LI, W. Palmprint feature extraction using 2-d gabor filters. **Pattern recognition**, Elsevier, v. 36, n. 10, p. 2339–2347, 2003. Citado na página 39.
- LIFSHITZ, L. M.; PIZER, S. M. A multiresolution hierarchical approach to image segmentation based on intensity extrema. In: SPRINGER. **Information Processing in Medical Imaging**. [S.l.], 1988. p. 107–130. Citado na página 52.
- MALIK, F.; BAHARUDIN, B. The statistical quantized histogram texture features analysis for image retrieval based on median and laplacian filters in the dct domain. **The International Arab Journal of Information Technology**, v. 10, n. 6, p. 1–9, 2013. Citado na página 35.
- MATERKA, A.; STRZELECKI, M. *et al.* Texture analysis methods—a review. **Technical university of lodz, institute of electronics, COST B11 report, Brussels**, p. 9–11, 1998. Citado na página 34.
- MATSUYAMA, T.; MIURA, S.-I.; NAGAO, M. Structural analysis of natural textures by fourier transformation. **Computer vision, graphics, and image processing**, Elsevier, v. 24, n. 3, p. 347–362, 1983. Citado na página 34.
- NEIL, G.; CURTIS, K. M. Shape recognition using fractal geometry. **Pattern Recognition**, Elsevier, v. 30, n. 12, p. 1957–1969, 1997. Citado na página 41.

NEUBAUER, C. Segmentation of defects in textile fabric. In: IEEE. **Pattern Recognition, 1992. Vol. I. Conference A: Computer Vision and Applications, Proceedings., 11th IAPR International Conference on**. [S.l.], 1992. p. 688–691. Citado na página 50.

OJALA, T.; MAENPAA, T.; PIETIKAINEN, M.; VIERTOLA, J.; KYLLONEN, J.; HUOVINEN, S. Outex-new framework for empirical evaluation of texture analysis algorithms. In: IEEE. **Pattern Recognition, 2002. Proceedings. 16th International Conference on**. [S.l.], 2002. v. 1, p. 701–706. Citado na página 65.

OJALA, T.; PIETIKÄINEN, M.; MÄENPÄÄ, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, IEEE, v. 24, n. 7, p. 971–987, 2002. Citado na página 38.

PARKER, J. R. **Algorithms for image processing and computer vision**. [S.l.]: John Wiley & Sons, 2010. Citado na página 58.

PERONA, P.; MALIK, J. Scale-space and edge detection using anisotropic diffusion. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, IEEE, v. 12, n. 7, p. 629–639, 1990. Citado 2 vezes nas páginas 53 e 54.

PERONA, P.; SHIOTA, T.; MALIK, J. Anisotropic diffusion. In: **Geometry-driven diffusion in computer vision**. [S.l.]: Springer, 1994. p. 73–92. Citado 3 vezes nas páginas 53, 54 e 55.

PICKARD, R.; GRASZYK, C.; MANN, S.; WACHMAN, J.; PICKARD, L.; CAMPBELL, L. Vistex database. **Media Lab., MIT, Cambridge, Massachusetts**, 1995. Citado na página 66.

RIBAS, L. C.; GONÇALVES, D. N.; ORUÊ, J. P. M.; GONÇALVES, W. N. Fractal dimension of maximum response filters applied to texture analysis. **Pattern Recognition Letters**, Elsevier, v. 65, p. 116–123, 2015. Citado na página 67.

ROSENFELD, A.; PFALTZ, J. L. Distance functions on digital pictures. **Pattern recognition**, Elsevier, v. 1, n. 1, p. 33–61, 1968. Citado na página 58.

RUSS, J. C.; WOODS, R. P. The image processing handbook. **Journal of Computer Assisted Tomography**, LWW, v. 19, n. 6, p. 979–981, 1995. Citado na página 33.

SAITO, T.; TORIWAKI, J.-I. New algorithms for euclidean distance transformation of an n -dimensional digitized picture with applications. **Pattern recognition**, Elsevier, v. 27, n. 11, p. 1551–1565, 1994. Citado na página 59.

SMOLA, A.; BARTLETT, P.; SCHÖLKOPF, B.; SCHUURMANS, D. Introduction to large margin classifiers. MIT Press, 2000. Citado na página 45.

TRICOT, C. **Curves and fractal dimension**. [S.l.]: Springer Science & Business Media, 1994. Citado na página 41.

TÜCERYAN, M.; JAIN, A. K. Texture segmentation using voronoi polygons. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, IEEE, v. 12, n. 2, p. 211–216, 1990. Citado na página 34.

USPTEx. **USPTEx dataset @ONLINE**. 2014. Disponível em: <http://fractal.ifsc.usp.br/dataset/USPtex.php>. Citado 6 vezes nas páginas 52, 54, 55, 56, 57 e 65.

VACAVANT, A.; ALBOUY-KISSI, A.; MENGUY, P.; SOLOMON, J. Fast smoothed shock filtering. In: IEEE. **Pattern Recognition (ICPR), 2012 21st International Conference on**. [S.l.], 2012. p. 182–185. Citado na página 57.

VINCENT, L.; SOILLE, P. Watersheds in digital spaces: an efficient algorithm based on immersion simulations. **IEEE Transactions on Pattern Analysis & Machine Intelligence**, IEEE, n. 6, p. 583–598, 1991. Citado na página 58.

WITKIN, A. P. Scale-space filtering: A new approach to multi-scale description. In: IEEE. **Acoustics, Speech, and Signal Processing, IEEE International Conference on ICASSP'84**. [S.l.], 1984. v. 9, p. 150–153. Citado na página 50.

XIANGHUA, X.; MIRMEHDI, M. Texems: Texture exemplars for defect detection on random textured surfaces. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, IEEE, v. 29, n. 8, p. 1454–1464, 2007. Citado na página 29.

XIE, X.; MIRMEHDI, M. Texems: Texture exemplars for defect detection on random textured surfaces. **IEEE Trans. Pattern Anal. Mach. Intell.**, v. 29, n. 8, p. 1454–1464, 2007. Disponível em: <<http://dblp.uni-trier.de/db/journals/pami/pami29.html#XieM07>>. Citado na página 29.

ZHANG, K. Existence of infinitely many solutions for the one-dimensional perona-malik model. **Calculus of Variations and Partial Differential Equations**, Springer, v. 26, n. 2, p. 171–199, 2006. Citado na página 55.

ZHAO, Y.; ZHANG, L.; LI, P. Texture feature fusion for high resolution satellite image classification. In: IEEE. **Computer Graphics, Imaging and Vision: New Trends, 2005. International Conference on**. [S.l.], 2005. p. 19–23. Citado 2 vezes nas páginas 29 e 33.

ZUCKER, S. W. Toward a model of texture. **Computer Graphics and Image Processing**, Elsevier, v. 5, n. 2, p. 190–202, 1976. Citado na página 34.

ZÚÑIGA, A. G.; FLORINDO, J. B.; BRUNO, O. M. Gabor wavelets combined with volumetric fractal dimension applied to texture analysis. **Pattern Recognition Letters**, Elsevier, v. 36, p. 135–143, 2014. Citado na página 30.

ZÚÑIGA, A. M. G. **Sistema de visão artificial para identificação do estado nutricional de plantas**. Tese (Doutorado) — Universidade de São Paulo, 2012. Citado na página 49.

RESULTADOS COM KNN

A.1 Difusão Linear

Tabela 13 – Resultados da aplicação de gaussiana como método de pré-processamento com diferentes extratores e KNN ($k = 3$) como classificador.

	KNN, $k = 3$							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
G+LBP	94.14 (1.06)	3	80.37 (3.11)	7	96.99 (2.27)	4	76.92 (1.40)	8
LBP	93.42(1.75)	-	73.24 (3.22)	-	96.06 (2.96)	-	72.16 (1.74)	-
ganho	0.72	↑	7.13	↑	0.93	↑	4.76	↑
G+Histogram	28.38 (3.16)	20	32.28 (3.69)	6	34.95 (5.47)	2	12.78 (1.74)	1
Histogram	26.22(2.80)	-	22.65 (2.96)	-	34.95 (5.47)	-	12.26 (1.41)	-
ganho	2.16	↑	9.63	↑	0.00	=	0.52	↑
G+GLCM	88.65 (2.39)	1	73.68 (3.40)	1	87.73 (2.42)	3	63.44 (3.21)	1
GLCM	87.03(2.59)	-	70.00 (5.48)	-	84.03 (3.25)	-	60.08 (2.62)	-
ganho	1.62	↑	3.68	↑	3.70	↑	3.36	↑
G+GLDM	85.59 (2.29)	2	68.46 (2.65)	2	79.98 (4.09)	4	52.49 (2.65)	1
GLDM	74.14(3.63)	-	47.06 (2.66)	-	56.13 (3.95)	-	31.98 (2.40)	-
ganho	11.44	↑	21.40	↑	23.84	↑	20.51	↑
G+Fourier	86.04 (2.47)	5	76.76 (2.38)	7	87.15 (1.54)	7	62.04 (3.04)	4
Fourier	84.41(2.69)	-	69.96 (3.16)	-	79.17 (4.28)	-	53.23 (3.00)	-
ganho	1.62	↑	6.80	↑	7.99	↑	8.81	↑
G+Gabor	92.52 (3.60)	5	81.84 (3.50)	7	94.33 (1.97)	10	75.79 (2.97)	6
Gabor	89.37(2.07)	-	70.88 (3.01)	-	86.34 (2.76)	-	66.80 (2.25)	-
ganho	3.15	↑	10.96	↑	7.99	↑	8.99	↑
G+Fractal	65.23 (3.83)	3	55.88 (3.47)	7	64.93 (4.66)	4	33.42 (1.73)	1
Fractal	48.83(3.70)	-	40.51 (3.76)	-	47.11 (4.74)	-	23.21 (2.58)	-
ganho	16.40	↑	15.37	↑	17.82	↑	10.21	↑

Fonte: Elaborada pelo autor.

Tabela 14 – Resultados da aplicação de gaussiana como método de pré-processamento com diferentes extratores e KNN (k = 5) como classificador.

	KNN, k= 5							
	Brodatz		Outex		Vistex		Usptex	
	melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>	
G+LBP	93.87 (0.93)	4	80.22 (3.86)	7	96.30 (2.01)	4	76.96 (2.12)	5
LBP	92.79(1.41)	-	74.41 (2.92)	-	94.21 (3.55)	-	73.17 (2.00)	-
ganho	1.08	↑	5.81	↑	2.08	↑	3.80	↑
G+Histogram	27.30 (3.20)	21	32.13 (3.81)	6	33.33 (2.91)	2	12.83 (0.99)	2
Histogram	25.41(4.18)	-	24.49 (3.06)	-	33.33 (2.91)	-	12.83 (0.99)	-
ganho	1.89	↑	7.65	↑	0.00	=	0.00	=
G+GLCM	85.68 (2.73)	1	72.50 (3.16)	1	84.49 (3.67)	3	61.43 (2.81)	1
GLCM	84.14(2.37)	-	68.60 (4.89)	-	81.94 (3.62)	-	58.42 (2.92)	-
ganho	1.53	↑	3.90	↑	2.55	↑	3.01	↑
G+GLDM	83.51 (2.08)	2	67.87 (3.33)	2	76.50 (5.20)	4	49.26 (3.82)	1
GLDM	69.91(4.10)	-	45.15 (1.44)	-	54.51 (4.71)	-	30.85 (1.60)	-
ganho	13.60	↑	22.72	↑	21.99	↑	18.41	↑
G+Fourier	84.77 (2.01)	3	76.99 (3.20)	7	85.53 (2.70)	7	61.43 (2.22)	7
Fourier	83.78(1.85)	-	66.84 (3.74)	-	78.59 (3.55)	-	54.62 (2.54)	-
ganho	0.99	↑	10.15	↑	6.94	↑	6.81	↑
G+Gabor	92.07 (2.73)	6	81.03 (2.22)	7	92.25 (3.38)	7	74.69 (1.98)	5
Gabor	88.11(3.12)	-	70.81 (3.47)	-	85.07 (4.42)	-	67.10 (2.89)	-
ganho	3.96	↑	10.22	↑	7.18	↑	7.59	↑
G+Fractal	64.05 (3.27)	4	54.19 (2.48)	8	62.62 (3.20)	4	32.72 (3.60)	6
Fractal	47.84(3.30)	-	37.79 (3.03)	-	45.37 (3.11)	-	22.69 (2.93)	-
ganho	16.22	↑	16.40	↑	17.25	↑	10.03	↑

Fonte: Elaborada pelo autor.

Tabela 15 – Resultados da aplicação de gaussiana como método de pré-processamento com diferentes extratores e KNN (k = 7) como classificador.

	KNN, k= 7							
	Brodatz		Outex		Vistex		Usptex	
	melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>	
G+LBP	92.43 (1.63)	1	80.37 (2.62)	8	95.37 (1.58)	4	75.96 (1.73)	1
LBP	91.89(1.85)	-	74.04 (3.20)	-	94.44 (3.28)	-	72.43 (2.49)	-
ganho	0.54	↑	6.32	↑	0.93	↑	3.53	↑
G+Histogram	24.68 (3.73)	1	30.37 (3.37)	6	33.56 (5.13)	2	12.17 (1.20)	1
Histogram	24.59(3.82)	-	24.71 (4.15)	-	33.56 (5.13)	-	11.91 (1.56)	-
ganho	0.09	↑	5.66	↑	0.00	=	0.26	↑
G+GLCM	82.61 (3.40)	3	71.03 (3.82)	1	82.99 (4.59)	3	60.25 (3.04)	1
GLCM	81.71(2.55)	-	66.91 (3.83)	-	78.70 (3.86)	-	55.72 (4.42)	-
ganho	0.90	↑	4.12	↑	4.28	↑	4.54	↑
G+GLDM	80.45 (2.33)	1	65.81 (2.84)	2	72.22 (5.03)	4	47.08 (2.75)	1
GLDM	67.75(3.42)	-	41.99 (1.97)	-	51.16 (4.84)	-	28.97 (2.43)	-
ganho	12.70	↑	23.82	↑	21.06	↑	18.11	↑
G+Fourier	83.15 (2.85)	5	75.66 (3.14)	6	83.22 (3.98)	6	60.21 (3.30)	7
Fourier	81.44(2.26)	-	65.96 (3.67)	-	76.97 (3.68)	-	53.80 (1.92)	-
ganho	1.71	↑	9.71	↑	6.25	↑	6.41	↑
G+Gabor	90.45 (2.21)	4	81.62 (2.31)	7	90.74 (3.47)	6	73.17 (2.35)	5
Gabor	87.12(2.40)	-	70.51 (2.83)	-	83.10 (2.72)	-	66.62 (3.63)	-
ganho	3.33	↑	11.10	↑	7.64	↑	6.54	↑
G+Fractal	61.17 (2.46)	4	52.57 (3.67)	8	60.88 (4.50)	4	30.58 (2.68)	6
Fractal	47.03(3.42)	-	34.63 (3.28)	-	44.91 (2.62)	-	21.25 (3.13)	-
ganho	14.14	↑	17.94	↑	15.97	↑	9.34	↑

Fonte: Elaborada pelo autor.

Tabela 16 – Resultados da aplicação de gaussiana como método de pré-processamento com diferentes extratores e KNN ($k = 9$) como classificador.

	KNN, $k=9$							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
G+LBP	91.44 (2.21)	3	79.41 (2.51)	9	93.98 (3.41)	1	75.13 (2.26)	1
LBP	90.90(1.67)	-	73.38 (2.75)	-	93.17 (3.98)	-	71.55 (2.65)	-
ganho	0.54	↑	6.03	↑	0.81	↑	3.58	↑
G+Histogram	23.87 (3.70)	21	30.88 (3.92)	6	32.29 (5.33)	2	12.26 (1.80)	2
Histogram	22.43(2.18)	-	23.16 (3.07)	-	32.29 (5.33)	-	12.26 (1.80)	-
ganho	1.44	↑	7.72	↑	0.00	=	0.00	=
G+GLCM	79.55 (2.75)	2	70.07 (3.53)	1	81.13 (4.08)	3	57.81 (2.80)	1
GLCM	79.55(2.75)	-	65.22 (4.60)	-	75.93 (5.64)	-	53.23 (3.12)	-
ganho	0.00	=	4.85	↑	5.21	↑	4.58	↑
G+GLDM	76.85 (2.44)	3	64.26 (3.57)	1	69.21 (4.82)	4	45.90 (2.99)	1
GLDM	65.41(4.19)	-	40.96 (2.43)	-	49.42 (3.67)	-	28.53 (2.92)	-
ganho	11.44	↑	23.31	↑	19.79	↑	17.36	↑
G+Fourier	80.90 (2.25)	3	74.85 (1.90)	6	81.60 (3.61)	8	58.68 (3.14)	7
Fourier	79.64(2.92)	-	73.35 (3.27)	-	75.12 (3.89)	-	53.66 (1.92)	-
ganho	1.26	↑	1.51	↑	6.48	↑	5.02	↑
G+Gabor	89.28 (2.28)	6	80.37 (2.41)	7	89.35 (2.85)	6	71.55 (3.14)	5
Gabor	86.22(2.65)	-	70.81 (3.22)	-	81.48 (3.82)	-	65.27 (3.90)	-
ganho	3.06	↑	9.56	↑	7.87	↑	6.28	↑
G+Fractal	59.10 (2.98)	3	49.19 (3.24)	7	58.56 (5.21)	6	29.54 (3.64)	5
Fractal	45.14(5.58)	-	33.24 (3.28)	-	43.06 (2.93)	-	20.24 (3.08)	-
ganho	13.96	↑	15.96	↑	15.51	↑	9.29	↑

Fonte: Elaborada pelo autor.

Tabela 17 – Resultados obtidos com a aplicação do algoritmo de difusão anisotrópica clássico nas imagens originais das bases. O ganho é resultante da diferença entre o melhor resultado quando se aplica a difusão e o resultado em qualquer aplicação de pré-processamento na avaliação do KNN, $k = 3$

	KNN, $k=3$							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
PM+LBP	96.67 (1.35)	34	73.53 (2.82)	16	98.84 (1.12)	17	81.15 (1.34)	16
LBP	93.42(1.75)	-	73.24 (3.22)	-	96.06 (2.96)	-	72.16 (1.74)	-
ganho	3.24	↑	0.29	↑	2.78	↑	8.99	↑
PM+Histogram	20.90 (2.84)	19	21.25 (3.28)	105	35.07 (4.82)	12	11.30 (2.09)	17
Histogram	26.22(2.80)	-	22.65 (2.96)	-	34.95 (5.47)	-	12.26 (1.41)	-
ganho	-5.32	↓	-1.40	↓	0.12	↑	-0.96	↓
PM+GLCM	65.32 (3.21)	4	49.93 (3.47)	2	73.61 (3.66)	1	51.31 (1.72)	1
GLCM	87.03(2.59)	-	70.00 (5.48)	-	84.03 (3.25)	-	60.08 (2.62)	-
ganho	-21.71	↓	-20.07	↓	-10.42	↓	-8.77	↓
PM+GLDM	86.04 (1.76)	77	63.68 (3.35)	105	76.16 (4.49)	92	50.44 (2.02)	28
GLDM	74.14(3.63)	-	47.06 (2.66)	-	56.13 (3.95)	-	31.98 (2.40)	-
ganho	11.89	↑	16.62	↑	20.02	↑	18.46	↑
PM+Fourier	86.04 (2.98)	51	70.00 (2.38)	38	82.52 (3.36)	51	61.39 (2.28)	29
Fourier	84.41(2.69)	-	66.69 (3.16)	-	79.17 (4.28)	-	53.23 (3.00)	-
ganho	1.62	↑	3.31	↑	3.36	↑	8.16	↑
PPM+Gabor	91.08 (1.61)	1	74.49 (4.11)	86	88.66 (2.66)	2	74.04 (3.12)	4
Gabor	89.37(2.07)	-	70.88 (3.01)	-	86.34 (2.76)	-	66.80 (2.25)	-
ganho	1.71	↑	3.60	↑	2.31	↑	7.24	↑
PM+Fractal	58.29 (4.92)	145	44.49 (4.10)	62	60.19 (3.82)	141	39.97 (2.07)	111
Fractal	48.83(3.70)	-	40.51 (3.76)	-	47.11 (4.74)	-	23.21 (2.58)	-
ganho	9.46	↑	3.97	↑	13.08	↑	16.75	↑

Fonte: Elaborada pelo autor.

A.2 Difusão Anisotrópica por Perona-Malik

Tabela 18 – Resultados obtidos com a aplicação do algoritmo de difusão anisotrópica clássico nas imagens originais das bases. O ganho é resultante da diferença entre o melhor resultado quando se aplica a difusão e o resultado em qualquer aplicação de pré-processamento na avaliação do KNN, $k = 5$

	KNN, $k = 5$							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
PM+LBP	96.80 (1.50)	33	75.15 (2.53)	140	97.45 (2.20)	8	80.41 (0.84)	28
LBP	95.86(1.41)	-	74.41 (2.92)	-	94.21 (3.55)	-	73.17 (2.00)	-
ganho	0.95	↑	0.74	↑	3.24	↑	7.24	↑
PM+Histogram	19.55 (3.90)	19	22.43 (2.43)	125	32.75 (5.28)	12	11.56 (2.33)	92
Histogram	25.41(4.18)	-	24.49 (3.06)	-	33.33 (2.91)	-	12.83 (0.99)	-
ganho	-5.86	↓	-2.06	↓	-0.58	↓	-1.27	↓
PM+GLCM	63.78 (5.04)	4	48.01 (3.37)	1	73.15 (4.63)	1	48.04 (2.41)	1
GLCM	84.14(2.37)	-	68.60 (4.89)	-	81.94 (3.62)	-	58.42 (2.92)	-
ganho	-20.36	↓	-20.59	↓	-8.80	↓	-10.38	↓
PM+GLDM	84.41 (1.70)	112	61.76 (3.23)	18	72.92 (4.94)	112	49.04 (2.36)	133
GLDM	69.91(4.10)	-	45.15 (1.44)	-	54.51 (4.71)	-	30.85 (1.60)	-
ganho	14.50	↑	16.62	↑	18.40	↑	18.19	↑
PM+Fourier	85.41 (2.00)	1	70.96 (3.51)	14	82.18 (5.08)	150	62.30 (2.63)	67
Fourier	83.78(1.85)	-	66.84 (3.74)	-	78.59 (3.55)	-	54.62 (2.54)	-
ganho	1.62	↑	4.12	↑	3.59	↑	7.68	↑
PM+Gabor	90.09 (2.63)	26	75.44 (3.62)	29	88.19 (1.91)	15	73.65 (2.89)	20
Gabor	88.11(3.12)	-	70.81 (3.47)	-	85.07 (4.42)	-	67.10 (2.89)	-
ganho	1.98	↑	4.63	↑	3.12	↑	6.54	↑
PM+Fractal	55.95 (3.81)	142	43.90 (4.95)	146	57.06 (4.14)	102	38.61 (1.86)	138
Fractal	47.84(3.30)	-	37.79 (3.03)	-	45.37 (3.11)	-	22.69 (2.93)	-
ganho	8.11	↑	6.10	↑	11.69	↑	15.92	↑

Fonte: Elaborada pelo autor.

Tabela 19 – Resultados obtidos com a aplicação do algoritmo de difusão anisotrópica clássico nas imagens originais das bases. O ganho é resultante da diferença entre o melhor resultado quando se aplica a difusão e o resultado em qualquer aplicação de pré-processamento na avaliação do KNN, $k = 7$

	KNN, $k = 7$							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
PM+LBP	96.80 (1.14)	35	76.69 (2.88)	119	96.88 (1.87)	23	79.23 (1.56)	29
LBP	94.64(1.85)	-	74.04 (3.20)	-	94.44 (3.28)	-	72.43 (2.49)	-
ganho	2.16	↑	2.65	↑	2.43	↑	6.81	↑
PM+Histogram	18.11 (2.21)	8	22.72 (2.36)	125	30.90 (3.82)	12	11.39 (2.46)	93
Histogram	24.59(3.82)	-	24.71 (4.15)	-	33.56 (5.13)	-	11.91 (1.56)	-
ganho	-6.49	↓	-1.99	↓	-2.66	↓	-0.52	↓
PM+GLCM	60.54 (3.13)	3	46.18 (3.18)	1	71.06 (4.23)	1	47.03 (2.71)	1
GLCM	81.71(2.55)	-	66.91 (3.83)	-	78.70 (3.86)	-	55.72 (4.42)	-
ganho	-21.17	↓	-20.74	↓	-7.64	↓	-8.68	↓
PM+GLDM	80.63 (2.34)	18	60.44 (1.83)	28	69.21 (5.67)	108	47.38 (2.87)	132
GLDM	67.75(3.42)	-	41.99 (1.97)	-	51.16 (4.84)	-	28.97 (2.43)	-
ganho	12.88	↑	18.46	↑	18.06	↑	18.41	↑
PM+Fourier	82.61 (3.10)	103	70.66 (2.15)	14	82.18 (3.31)	69	62.04 (1.78)	40
Fourier	81.44(2.26)	-	65.96 (3.67)	-	76.97 (3.68)	-	53.80 (1.92)	-
ganho	1.17	↑	4.71	↑	5.21	↑	8.25	↑
PM+Gabor	88.56 (3.03)	15	74.41 (4.71)	7	86.34 (2.45)	46	72.91 (2.57)	19
Gabor	87.12(2.40)	-	70.51 (2.83)	-	83.10 (2.72)	-	66.62 (3.63)	-
ganho	1.44	↑	3.90	↑	3.24	↑	6.28	↑
PM+Fractal	53.78 (3.68)	148	43.31 (3.44)	18	56.71 (2.86)	100	37.78 (2.63)	145
Fractal	47.03(3.42)	-	34.63 (3.28)	-	44.91 (2.62)	-	21.25 (3.13)	-
ganho	6.76	↑	8.68	↑	11.81	↑	16.54	↑

Fonte: Elaborada pelo autor.

Tabela 20 – Resultados obtidos com a aplicação do algoritmo de difusão anisotrópica clássico nas imagens originais das bases. O ganho é resultante da diferença entre o melhor resultado quando se aplica a difusão e o resultado em qualquer aplicação de pré-processamento na avaliação do KNN, $k = 9$

	KNN, $k = 9$							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
PM+LBP	93.42 (1.50)	25	75.74 (2.22)	140	95.83 (1.51)	14	78.66 (1.47)	29
LBP	94.55(1.67)	-	73.38 (2.75)	-	93.17 (3.98)	-	71.55 (2.65)	-
ganho	-1.13	↓	2.35	↑	2.66	↑	7.11	↑
PM+Histogram	17.66 (3.38)	31	21.69 (2.95)	115	29.40 (3.79)	79	11.52 (2.35)	92
Histogram	22.43(2.18)	-	23.16 (3.07)	-	32.29 (5.33)	-	12.26 (1.80)	-
ganho	-4.77	↓	-1.47	↓	-2.89	↓	-0.74	↓
PM+GLCM	56.67 (3.51)	4	45.88 (2.69)	1	67.94 (4.08)	1	44.15 (1.48)	1
GLCM	79.55(2.75)	-	65.22 (4.60)	-	75.93 (5.64)	-	53.23 (3.12)	-
ganho	-22.88	↓	-19.34	↓	-7.99	↓	-9.08	↓
PM+GLDM	78.56 (4.00)	24	59.41 (3.27)	34	65.97 (5.93)	63	45.68 (3.38)	61
GLDM	65.41(4.19)	-	40.96 (2.43)	-	49.42 (3.67)	-	28.53 (2.92)	-
ganho	13.15	↑	18.46	↑	16.55	↑	17.15	↑
PM+Fourier	82.61 (3.10)	103	70.66 (2.15)	14	82.18 (3.31)	69	62.04 (1.78)	40
Fourier	81.44(2.26)	-	65.96 (3.67)	-	76.97 (3.68)	-	53.80 (1.92)	-
ganho	1.17	↑	4.71	↑	5.21	↑	8.25	↑
PM+Gabor	87.21 (3.12)	117	73.53 (3.11)	8	84.95 (3.58)	1	72.38 (2.19)	10
Gabor	86.22(2.65)	-	70.81 (3.22)	-	81.48 (3.82)	-	65.27 (3.90)	-
ganho	0.99	↑	2.72	↑	3.47	↑	7.11	↑
PM+Fractal	52.61 (4.38)	150	42.79 (4.10)	149	56.60 (3.10)	127	35.65 (2.21)	143
Fractal	45.14(5.58)	-	33.24 (3.28)	-	43.06 (2.93)	-	20.24 (3.08)	-
ganho	7.48	↑	9.56	↑	13.54	↑	15.40	↑

Fonte: Elaborada pelo autor.

Tabela 21 – Resultados da aplicação da regularização forward-backward da difusão anisotrópica, são 150 iterações testas e a coluna melhor i apresenta a iteração que mostrou o melhor resultado. A tabela mostra os resultados para KNN, $k = 3$.

	KNN, $k = 3$							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
FBR+LBP	96.58 (1.58)	40	79.56 (2.84)	93	98.61 (1.11)	27	82.77 (1.04)	79
LBP	93.42(1.75)	-	73.24 (3.22)	-	96.06 (2.96)	-	72.16 (1.74)	-
ganho	3.15	↑	6.32	↑	2.55	↑	10.60	↑
BR+Histogram	21.89 (2.41)	50	21.62 (3.91)	123	33.22 (4.94)	11	10.82 (2.21)	13
Histogram	26.22(2.80)	-	22.65 (2.96)	-	34.95 (5.47)	-	12.26 (1.41)	-
ganho	-4.32	↓	-1.03	↓	-1.74	↓	-1.44	↓
FBR+GLCM	63.60 (3.21)	1	48.68 (4.11)	1	73.50 (4.27)	1	51.53 (1.86)	1
GLCM	87.03(2.59)	-	70.00 (5.48)	-	84.03 (3.25)	-	60.08 (2.62)	-
ganho	-23.42	↓	-21.32	↓	-10.53	↓	-8.55	↓
FBR+GLDM	86.85 (2.05)	89	65.00 (3.14)	89	77.31 (4.75)	137	51.05 (3.02)	85
GLDM	74.14(3.63)	-	47.06 (2.66)	-	56.13 (3.95)	-	31.98 (2.40)	-
ganho	12.70	↑	17.94	↑	21.18	↑	19.07	↑
FBR+Fourier	85.95 (3.27)	1	70.22 (2.45)	20	82.41 (3.32)	108	61.13 (2.27)	26
Fourier	84.41(2.69)	-	66.69 (3.16)	-	79.17 (4.28)	-	53.23 (3.00)	-
ganho	1.53	↑	3.53	↑	3.24	↑	7.90	↑
FBR+Gabor	91.08 (1.61)	1	74.41 (3.47)	16	88.77 (2.70)	48	74.17 (3.28)	5
Gabor	89.37(2.07)	-	70.88 (3.01)	-	86.34 (2.76)	-	66.80 (2.25)	-
ganho	1.71	↑	3.53	↑	2.43	↑	7.37	↑
FBR+Fractal	58.65 (5.09)	147	45.59 (5.11)	93	61.00 (4.44)	148	40.01 (2.15)	121
Fractal	48.83(3.70)	-	40.51 (3.76)	-	47.11 (4.74)	-	23.21 (2.58)	-
ganho	9.82	↑	5.07	↑	13.89	↑	16.80	↑

Fonte: Elaborada pelo autor.

A.3 Regularização Forward-Backward da Difusão Anisotrópica

Tabela 22 – Resultados da aplicação da regularização forward-backward da difusão anisotrópica, são 150 iterações testas e a coluna melhor i apresenta a iteração que mostrou o melhor resultado. A tabela mostra os resultados para KNN, $k = 5$.

	KNN, $k = 5$							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
FBR+LBP	95.41 (1.69)	59	81.18 (2.82)	45	97.69 (1.44)	22	81.37 (1.86)	24
LBP	92.79(1.41)	-	74.41 (2.92)	-	94.21 (3.55)	-	73.17 (2.00)	-
ganho	2.61	↑	6.76	↑	3.47	↑	8.20	↑
FBR+Histogram	20.63 (2.94)	136	23.82 (3.75)	123	31.60 (3.73)	15	10.95 (1.22)	2
Histogram	25.41(4.18)	-	24.49 (3.06)	-	33.33 (2.91)	-	12.83 (0.99)	-
ganho	-4.77	↓	-0.66	↓	-1.74	↓	-1.88	↓
FBR+GLCM	62.34 (3.61)	4	47.13 (4.07)	2	72.22 (4.35)	1	48.30 (2.56)	1
GLCM	84.14(2.37)	-	68.60 (4.89)	-	81.94 (3.62)	-	58.42 (2.92)	-
ganho	-21.80	↓	-21.47	↓	-9.72	↓	-10.12	↓
FBR+GLDM	84.95 (1.47)	58	63.38 (2.75)	56	72.69 (4.60)	100	49.04 (2.04)	65
GLDM	69.91(4.10)	-	45.15 (1.44)	-	54.51 (4.71)	-	30.85 (1.60)	-
ganho	15.05	↑	18.24	↑	18.17	↑	18.19	↑
FBR+Fourier	85.41 (1.91)	1	70.96 (3.08)	8	83.22 (4.68)	110	61.47 (2.83)	9
Fourier	83.78(1.85)	-	66.84 (3.74)	-	78.59 (3.55)	-	54.62 (2.54)	-
ganho	1.62	↑	4.12	↑	4.63	↑	6.85	↑
FBR+Gabor	89.82 (2.69)	8	75.07 (4.05)	23	88.31 (2.26)	19	73.39 (2.62)	14
Gabor	88.11(3.12)	-	70.81 (3.47)	-	85.07 (4.42)	-	67.10 (2.89)	-
ganho	1.71	↑	4.26	↑	3.24	↑	6.28	↑
FBR+Fractal	57.39 (3.92)	150	45.37 (3.52)	108	57.75 (2.39)	76	38.66 (3.40)	127
Fractal	47.84(3.30)	-	37.79 (3.03)	-	45.37 (3.11)	-	22.69 (2.93)	-
ganho	9.55	↑	7.57	↑	12.38	↑	15.97	↑

Fonte: Elaborada pelo autor.

Tabela 23 – Resultados da aplicação da regularização forward-backward da difusão anisotrópica, são 150 iterações testas e a coluna melhor i apresenta a iteração que mostrou o melhor resultado. A tabela mostra os resultados para KNN, $k = 7$.

	KNN, $k = 7$							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
FBR+LBP	94.23 (1.66)	10	81.18 (3.42)	29	96.64 (1.72)	22	80.15 (2.34)	22
LBP	91.89(1.85)	-	74.04 (3.20)	-	94.44 (3.28)	-	72.43 (2.49)	-
ganho	2.34	↑	7.13	↑	2.20	↑	7.72	↑
FBR+Histogram	19.01 (3.15)	150	23.53 (3.62)	149	30.90 (4.79)	42	11.04 (1.88)	33
Histogram	24.59(3.82)	-	24.71 (4.15)	-	33.56 (5.13)	-	11.91 (1.56)	-
ganho	-5.59	↓	-1.18	↓	-2.66	↓	-0.87	↓
FBR+GLCM	59.28 (4.81)	1	45.15 (4.21)	2	70.49 (4.78)	1	47.29 (2.49)	1
GLCM	81.71(2.55)	-	66.91 (3.83)	-	78.70 (3.86)	-	55.72 (4.42)	-
ganho	-22.43	↓	-21.76	↓	-8.22	↓	-8.42	↓
FBR+GLDM	80.90 (2.47)	94	61.76 (3.57)	84	69.10 (5.63)	149	47.86 (3.78)	103
GLDM	67.75(3.42)	-	41.99 (1.97)	-	51.16 (4.84)	-	28.97 (2.43)	-
ganho	13.15	↑	19.78	↑	17.94	↑	18.89	↑
FBR+Fourier	83.33 (2.33)	92	70.51 (2.15)	10	82.52 (1.87)	112	61.56 (2.77)	57
Fourier	81.44(2.26)	-	65.96 (3.67)	-	76.97 (3.68)	-	53.80 (1.92)	-
ganho	1.89	↑	4.56	↑	5.56	↑	7.77	↑
FBR+Gabor	88.56 (3.14)	5	74.56 (4.59)	9	86.81 (3.39)	92	72.77 (3.04)	3
Gabor	87.12(2.40)	-	70.51 (2.83)	-	83.10 (2.72)	-	66.62 (3.63)	-
ganho	1.44	↑	4.04	↑	3.70	↑	6.15	↑
FBR+Fractal	54.86 (3.25)	94	43.90 (3.73)	110	56.71 (5.48)	147	38.00 (2.03)	128
Fractal	47.03(3.42)	-	34.63 (3.28)	-	44.91 (2.62)	-	21.25 (3.13)	-
ganho	7.84	↑	9.26	↑	11.81	↑	16.75	↑

Fonte: Elaborada pelo autor.

Tabela 24 – Resultados da aplicação da regularização forward-backward da difusão anisotrópica, são 150 iterações testas e a coluna melhor i apresenta a iteração que mostrou o melhor resultado. A tabela mostra os resultados para KNN, $k = 9$.

	KNN, $k = 9$							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
FBR+LBP	93.51 (1.72)	97	80.88 (2.60)	22	95.83 (1.73)	64	79.67 (2.16)	21
LBP	90.90(1.67)	-	73.38 (2.75)	-	93.17 (3.98)	-	71.55 (2.65)	-
ganho	2.61	↑	7.50	↑	2.66	↑	8.12	↑
FBR+Histogram	18.20 (3.44)	141	22.57 (3.62)	147	29.51 (3.62)	41	11.13 (1.52)	33
Histogram	22.43(2.18)	-	23.16 (3.07)	-	32.29 (5.33)	-	12.26 (1.80)	-
ganho	-4.23	↓	-0.59	↓	-2.78	↓	-1.13	↓
FBR+GLCM	56.04 (4.77)	1	44.34 (3.00)	1	67.94 (4.38)	1	44.68 (1.51)	1
GLCM	79.55(2.75)	-	65.22 (4.60)	-	75.93 (5.64)	-	53.23 (3.12)	-
ganho	-23.51	↓	-20.88	↓	-7.99	↓	-8.55	↓
FBR+GLDM	78.47 (3.93)	14	60.66 (3.03)	76	67.25 (6.94)	43	46.34 (3.50)	122
GLDM	65.41(4.19)	-	40.96 (2.43)	-	49.42 (3.67)	-	28.53 (2.92)	-
ganho	13.06	↑	19.71	↑	17.82	↑	17.80	↑
FBR+Fourier	81.44 (3.06)	101	69.63 (3.14)	5	80.56 (3.57)	115	60.47 (2.12)	9
Fourier	79.64(2.92)	-	65.96 (3.27)	-	75.12 (3.89)	-	53.66 (1.92)	-
ganho	1.80	↑	3.68	↑	5.44	↑	6.81	↑
FBR+Gabor	87.12 (2.27)	14	73.46 (2.88)	42	85.53 (2.65)	132	72.21 (2.33)	7
Gabor	86.22(2.65)	-	70.81 (3.22)	-	81.48 (3.82)	-	65.27 (3.90)	-
ganho	0.90	↑	2.65	↑	4.05	↑	6.94	↑
FBR+Fractal	52.52 (3.29)	52	42.43 (4.04)	69	56.60 (5.00)	138	36.43 (2.48)	115
Fractal	45.14(5.58)	-	33.24 (3.28)	-	43.06 (2.93)	-	20.24 (3.08)	-
ganho	7.39	↑	9.19	↑	13.54	↑	16.19	↑

Fonte: Elaborada pelo autor.

Tabela 25 – A tabela mostra os resultados da aplicação da difusão anisotrópica não local com os diferentes descritores e KNN, $k = 3$

	KNN, $k = 3$							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
NL+LBP	95.50 (1.76)	137	76.03 (2.82)	122	96.53 (2.52)	100	76.88 (2.20)	142
LBP	93.42(1.75)	-	73.24 (3.22)	-	96.06 (2.96)	-	72.16 (1.74)	-
ganho	2.07	↑	2.79	↑	0.46	↑	4.71	↑
NL+Histogram	18.20 (2.20)	43	20.15 (2.60)	118	30.44 (2.86)	5	11.69 (2.03)	88
Histogram	26.22(2.80)	-	22.65 (2.96)	-	34.95 (5.47)	-	12.26 (1.41)	-
ganho	-8.02	↓	-2.50	↓	-4.51	↓	-0.57	↓
NL+GLCM	65.41 (4.62)	126	54.49 (2.06)	42	76.04 (3.89)	43	54.06 (3.62)	1
GLCM	87.03(2.59)	-	70.00 (5.48)	-	84.03 (3.25)	-	60.08 (2.62)	-
ganho	-21.62	↓	-15.51	↓	-7.99	↓	-6.02	↓
NL+GLDM	86.04 (2.05)	70	66.84 (2.41)	1	76.39 (4.07)	2	52.31 (2.04)	1
GLDM	74.14(3.63)	-	47.06 (2.66)	-	56.13 (3.95)	-	31.98 (2.40)	-
ganho	11.89	↑	19.78	↑	20.25	↑	20.33	↑
NL+Fourier	86.04 (3.24)	3	71.32 (2.88)	96	82.52 (3.38)	145	61.87 (2.41)	114
Fourier	84.41(2.69)	-	66.69 (3.16)	-	79.17 (4.28)	-	53.23 (3.00)	-
ganho	1.62	↑	4.63	↑	3.36	↑	8.64	↑
NL+Gabor	91.08 (1.61)	9	75.81 (2.91)	62	89.12 (2.81)	137	74.39 (3.30)	39
Gabor	89.37(2.07)	-	70.88 (3.01)	-	86.34 (2.76)	-	66.80 (2.25)	-
ganho	1.71	↑	4.93	↑	2.78	↑	7.59	↑
NL+Fractal	52.16 (3.44)	146	40.66 (2.60)	9	55.90 (4.18)	28	33.38 (2.58)	141
Fractal	48.83(3.70)	-	40.51 (3.76)	-	47.11 (4.74)	-	23.21 (2.58)	-
ganho	3.33	↑	0.15	↑	8.80	↑	10.17	↑

Fonte: Elaborada pelo autor.

A.4 Difusão Anisotrópica Não Local

Tabela 26 – A tabela mostra os resultados da aplicação da difusão anisotrópica não local com os diferentes descritores e KNN, k = 5

	KNN, k = 5							
	Brodatz		Outex		Vistex		Usptex	
	melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>	
NL+LBP	94.77 (1.53)	103	76.76 (2.64)	102	96.06 (2.32)	107	77.01 (1.08)	145
LBP	92.79(1.41)	-	74.41 (2.92)	-	94.21 (3.55)	-	73.17 (2.00)	-
ganho	1.98	↑	2.35	↑	1.85	↑	3.84	↑
NL+Histogram	18.83 (3.09)	94	21.25 (2.70)	118	29.05 (2.91)	78	12.48 (1.62)	127
Histogram	25.41(4.18)	-	24.49 (3.06)	-	33.33 (2.91)	-	12.83 (0.99)	-
ganho	-6.58	↓	-3.24	↓	-4.28	↓	-0.35	↓
NL+GLCM	63.42 (4.06)	129	54.12 (3.50)	1	74.54 (3.52)	25	51.96 (3.84)	1
GLCM	84.14(2.37)	-	68.60 (4.89)	-	89.58 (3.62)	-	58.42 (2.92)	-
ganho	-20.72	↓	-14.49	↓	-15.05	↓	-6.46	↓
NL+GLDM	83.87 (1.97)	1	66.25 (2.69)	1	72.57 (2.82)	5	49.61 (2.86)	1
GLDM	69.91(4.10)	-	45.15 (1.44)	-	54.51 (4.71)	-	30.85 (1.60)	-
ganho	13.96	↑	21.10	↑	18.06	↑	18.76	↑
NL+Fourier	85.41 (1.91)	1	71.84 (2.80)	72	81.48 (3.80)	11	62.83 (2.19)	136
Fourier	83.78(1.85)	-	66.84 (3.74)	-	78.59 (3.55)	-	54.62 (2.54)	-
ganho	1.62	↑	5.00	↑	2.89	↑	8.20	↑
NL+Gabor	89.91 (2.77)	121	76.69 (4.21)	50	88.31 (2.26)	117	73.69 (2.49)	21
Gabor	88.11(3.12)	-	70.81 (3.47)	-	85.07 (4.42)	-	67.10 (2.89)	-
ganho	1.80	↑	5.88	↑	3.24	↑	6.59	↑
NL+Fractal	51.44 (3.02)	129	40.07 (2.71)	13	55.67 (4.25)	26	32.33 (2.32)	121
Fractal	47.84(3.30)	-	37.79 (3.03)	-	45.37 (3.11)	-	22.69 (2.93)	-
ganho	3.60	↑	2.28	↑	10.30	↑	9.64	↑

Fonte: Elaborada pelo autor.

Tabela 27 – A tabela mostra os resultados da aplicação da difusão anisotrópica não local com os diferentes descritores e KNN, k = 7

	KNN, k = 7							
	Brodatz		Outex		Vistex		Usptex	
	melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>	
NL+LBP	94.14 (1.56)	105	77.35 (3.08)	121	95.02 (2.63)	136	75.35 (1.20)	142
LBP	91.89(1.85)	-	74.04 (3.20)	-	94.44 (3.28)	-	72.43 (2.49)	-
ganho	2.25	↑	3.31	↑	0.58	↑	2.92	↑
NL+Histogram	17.39 (2.09)	41	21.03 (2.62)	138	28.47 (2.82)	133	12.00 (2.17)	92
Histogram	24.59(3.82)	-	24.71 (4.15)	-	33.56 (5.13)	-	11.91 (1.56)	-
ganho	-7.21	↓	-3.68	↓	-5.09	↓	0.09	↑
NL+GLCM	61.44 (4.82)	143	51.91 (2.90)	1	72.22 (4.83)	43	48.73 (3.43)	1
GLCM	81.71(2.55)	-	66.91 (3.83)	-	78.70 (3.86)	-	55.72 (4.42)	-
ganho	-20.27	↓	-15.00	↓	-6.48	↓	-6.98	↓
NL+GLDM	80.63 (2.98)	76	64.34 (2.88)	1	68.87 (4.93)	8	48.69 (2.19)	1
GLDM	67.75(3.42)	-	41.99 (1.97)	-	51.16 (4.84)	-	28.97 (2.43)	-
ganho	12.88	↑	22.35	↑	17.71	↑	19.72	↑
NL+Fourier	82.52 (3.02)	1	70.81 (3.34)	105	81.37 (2.95)	114	62.70 (2.25)	150
Fourier	81.44(2.26)	-	65.96 (3.67)	-	76.97 (3.68)	-	53.80 (1.92)	-
ganho	1.08	↑	4.85	↑	4.40	↑	8.90	↑
NL+Gabor	88.47 (3.14)	64	76.03 (4.47)	57	86.34 (3.16)	106	73.30 (2.77)	37
Gabor	87.12(2.40)	-	70.51 (2.83)	-	83.10 (2.72)	-	66.62 (3.63)	-
ganho	1.35	↑	5.51	↑	3.24	↑	6.68	↑
NL+Fractal	50.99 (5.08)	147	39.19 (4.12)	9	53.70 (4.11)	91	31.50 (2.12)	145
Fractal	47.03(3.42)	-	34.63 (3.28)	-	44.91 (2.62)	-	21.25 (3.13)	-
ganho	3.96	↑	4.56	↑	8.80	↑	10.25	↑

Fonte: Elaborada pelo autor.

Tabela 28 – A tabela mostra os resultados da aplicação da difusão anisotrópica não local com os diferentes descritores e KNN, $k = 9$

	KNN, knn = 9							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
NL+LBP	92.43 (1.70)	135	77.13 (2.44)	100	94.33 (3.28)	89	74.87 (1.48)	144
LBP	90.90(1.67)	-	73.38 (2.75)	-	93.17 (3.98)	-	71.55 (2.65)	-
ganho	1.53	↑	3.75	↑	1.16	↑	3.32	↑
NL+Histogram	16.67 (2.25)	79	19.63 (2.93)	59	26.97 (3.59)	142	11.52 (1.69)	94
Histogram	22.43(2.18)	-	23.16 (3.07)	-	32.29 (5.33)	-	12.26 (1.80)	-
ganho	-5.77	↓	-3.53	↓	-5.32	↓	-0.74	↓
NL+GLCM	59.64 (5.73)	141	51.18 (4.32)	149	69.91 (4.63)	44	47.60 (2.52)	1
GLCM	79.55(2.75)	-	65.22 (4.60)	-	86.81 (5.64)	-	53.23 (3.12)	-
ganho	-19.91	↓	-14.04	↓	-16.90	↓	-5.63	↓
NL+GLDM	78.02 (3.58)	1	62.21 (2.73)	1	65.86 (5.85)	8	47.12 (2.45)	1
GLDM	65.41(4.19)	-	40.96 (2.43)	-	49.42 (3.67)	-	28.53 (2.92)	-
ganho	12.61	↑	21.25	↑	16.44	↑	18.59	↑
NL+Fourier	80.18 (2.66)	1	70.81 (4.02)	137	80.32 (3.76)	24	61.61 (2.02)	150
Fourier	79.64(2.92)	-	65.96 (3.27)	-	75.12 (3.89)	-	53.66 (1.92)	-
ganho	0.54	↑	4.85	↑	5.21	↑	7.94	↑
NL+Gabor	86.94 (2.33)	1	75.22 (3.92)	66	85.19 (3.33)	122	72.29 (3.00)	20
Gabor	86.22(2.65)	-	70.81 (3.22)	-	81.48 (3.82)	-	65.27 (3.90)	-
ganho	0.72	↑	4.41	↑	3.70	↑	7.02	↑
NL+Fractal	50.90 (3.87)	93	36.62 (2.92)	5	53.24 (3.40)	103	30.80 (2.87)	150
Fractal	45.14(5.58)	-	33.24 (3.28)	-	43.06 (2.93)	-	20.24 (3.08)	-
ganho	5.77	↑	3.38	↑	10.19	↑	10.56	↑

Fonte: Elaborada pelo autor.

Tabela 29 – Resultados da aplicação do filtro morfológico nas imagens dos quatro banco de dados com a análise de diferentes descritores e classificador KNN (k = 3).

	KNN, k = 3							
	Brodatz		Outex		Vistex		Usptex	
	melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>	
SF+LBP	94.50 (2.24)	1	76.69 (3.15)	1	96.53 (1.14)	3	78.93 (2.51)	5
LBP	93.42(1.75)	-	73.24 (3.22)	-	96.06 (2.96)	-	72.16 (1.74)	-
ganho	1.08	↑	3.46	↑	0.46	↑	6.76	↑
SF+Histogram	9.91 (1.59)	5	27.21 (4.58)	5	22.22 (2.94)	1	10.65 (1.75)	5
Histogram	26.22(2.80)	-	22.65 (2.96)	-	34.95 (5.47)	-	12.26 (1.41)	-
ganho	-16.31	↓	4.56	↑	-12.73	↓	-1.61	↓
SF+GLCM	89.91 (2.36)	4	76.10 (3.33)	5	86.92 (3.81)	4	68.41 (4.16)	5
GLCM	87.03(2.59)	-	70.00 (5.48)	-	84.03 (3.25)	-	60.08 (2.62)	-
ganho	2.88	↑	6.10	↑	2.89	↑	8.33	↑
SF+GLDM	85.41 (2.28)	1	69.04 (3.17)	2	75.81 (4.39)	2	49.78 (2.45)	1
GLDM	74.14(3.63)	-	47.06 (2.66)	-	56.13 (3.95)	-	31.98 (2.40)	-
ganho	11.26	↑	21.99	↑	19.68	↑	17.80	↑
SF+Fourier	84.59 (2.88)	1	68.31 (2.80)	1	80.32 (2.80)	1	57.16 (3.00)	1
Fourier	84.41(2.69)	-	66.69 (3.16)	-	79.17 (4.28)	-	53.23 (3.00)	-
ganho	0.18	↑	1.62	↑	1.16	↑	3.93	↑
SF+Gabor	89.01 (2.13)	2	70.37 (2.84)	2	85.65 (2.89)	1	67.71 (3.33)	5
Gabor	89.37(2.07)	-	70.88 (3.01)	-	86.34 (2.76)	-	66.80 (2.25)	-
ganho	-0.36	↓	-0.51	↓	-0.69	↓	0.92	↑
SF+Fractal	69.28 (4.26)	2	49.26 (4.73)	4	63.54 (4.48)	4	40.18 (3.21)	5
Fractal	48.83(3.70)	-	40.51 (3.76)	-	47.11 (4.74)	-	23.21 (2.58)	-
ganho	20.45	↑	8.75	↑	16.44	↑	16.97	↑

Fonte: Elaborada pelo autor.

A.5 Espaço de Escala gerado por Morfologia Matemática

Tabela 30 – Resultados da aplicação do filtro morfológico nas imagens dos quatro banco de dados com a análise de diferentes descritores e classificador KNN (k = 5).

	KNN, k = 5							
	Brodatz		Outex		Vistex		Usptex	
	melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>	
F+LBP	94.14 (2.09)	1	78.68 (4.09)	5	96.53 (1.46)	2	78.80 (2.55)	5
LBP	92.79(1.41)	-	74.41 (2.92)	-	94.21 (3.55)	-	73.17 (2.00)	-
ganho	1.35	↑	4.26	↑	2.31	↑	5.63	↑
SF+Histogram	9.46 (0.95)	4	28.68 (4.07)	5	22.22 (3.25)	1	10.56 (1.77)	1
Histogram	25.41(4.18)	-	24.49 (3.06)	-	33.33 (2.91)	-	12.83 (0.99)	-
ganho	-15.95	↓	4.19	↑	-11.11	↓	-2.27	↓
SF+GLCM	88.02 (1.67)	3	74.85 (3.06)	5	84.26 (4.07)	3	67.36 (4.49)	4
GLCM	84.14(2.37)	-	68.60 (4.89)	-	81.94 (3.62)	-	58.42 (2.92)	-
ganho	3.87	↑	6.25	↑	2.31	↑	8.94	↑
SF+GLDM	83.15 (2.40)	1	66.76 (3.53)	5	71.41 (5.23)	1	48.21 (3.24)	1
GLDM	69.91(4.10)	-	45.15 (1.44)	-	54.51 (4.71)	-	30.85 (1.60)	-
ganho	13.24	↑	21.62	↑	16.90	↑	17.36	↑
SF+Fourier	83.06 (1.99)	1	68.09 (2.99)	5	78.36 (2.42)	1	58.07 (3.09)	5
Fourier	83.78(1.85)	-	66.84 (3.74)	-	78.59 (3.55)	-	54.62 (2.54)	-
ganho	-0.72	↓	1.25	↑	-0.23	↓	3.45	↑
SF+Gabor	87.30 (2.97)	1	71.18 (3.47)	2	84.84 (2.24)	1	68.59 (3.81)	1
Gabor	88.11(3.12)	-	70.81 (3.47)	-	85.07 (4.42)	-	67.10 (2.89)	-
ganho	-0.81	↓	0.37	↑	-0.23	↓	1.48	↑
SF+Fractal	65.23 (2.21)	3	48.31 (6.01)	3	61.81 (4.37)	4	38.31 (3.56)	5
Fractal	47.84(3.30)	-	37.79 (3.03)	-	45.37 (3.11)	-	22.69 (2.93)	-
ganho	17.39	↑	10.51	↑	16.44	↑	15.62	↑

Fonte: Elaborada pelo autor.

Tabela 31 – Resultados da aplicação do filtro morfológico nas imagens dos quatro banco de dados com a análise de diferentes descritores e classificador KNN (k = 7).

	KNN, k = 7							
	Brodatz		Outex		Vistex		Usptex	
	melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>	
SF+LBP	92.79 (2.83)	1	78.60 (2.33)	5	96.18 (2.58)	1	77.97 (1.70)	5
LBP	91.89(1.85)	-	74.04 (3.20)	-	94.44 (3.28)	-	72.43 (2.49)	-
ganho	0.90	↑	4.56	↑	1.74	↑	5.54	↑
SF+Histogram	10.09 (1.48)	5	27.72 (4.61)	5	21.06 (2.69)	1	11.17 (1.71)	5
Histogram	24.59(3.82)	-	24.71 (4.15)	-	33.56 (5.13)	-	11.91 (1.56)	-
ganho	-14.50	↓	3.01	↑	-12.50	↓	-0.74	↓
SF+GLCM	85.77 (2.54)	3	71.99 (2.41)	5	82.18 (3.36)	5	65.23 (4.53)	5
GLCM	81.71(2.55)	-	66.91 (3.83)	-	78.70 (3.86)	-	55.72 (4.42)	-
ganho	4.05	↑	5.07	↑	3.47	↑	9.51	↑
SF+GLDM	80.63 (2.26)	1	65.51 (3.37)	2	67.94 (4.39)	2	46.03 (3.31)	1
GLDM	67.75(3.42)	-	41.99 (1.97)	-	51.16 (4.84)	-	28.97 (2.43)	-
ganho	12.88	↑	23.53	↑	16.78	↑	17.06	↑
SF+Fourier	81.17 (3.06)	1	66.99 (2.70)	2	76.39 (3.10)	2	57.50 (3.42)	5
Fourier	81.44(2.26)	-	65.96 (3.67)	-	76.97 (3.68)	-	53.80 (1.92)	-
ganho	-0.27	↓	1.03	↑	-0.58	↓	3.71	↑
SF+Gabor	86.67 (2.69)	3	70.81 (2.86)	2	83.56 (3.08)	1	67.50 (3.93)	1
Gabor	87.12(2.40)	-	70.51 (2.83)	-	83.10 (2.72)	-	66.62 (3.63)	-
ganho	-0.45	↓	0.29	↑	0.46	↑	0.87	↑
SF+Fractal	62.88 (2.20)	4	46.84 (4.61)	5	56.71 (5.44)	5	36.17 (3.44)	5
Fractal	47.03(3.42)	-	34.63 (3.28)	-	44.91 (2.62)	-	21.25 (3.13)	-
ganho	15.86	↑	12.21	↑	11.81	↑	14.92	↑

Fonte: Elaborada pelo autor.

Tabela 32 – Resultados da aplicação do filtro morfológico nas imagens dos quatro banco de dados com a análise de diferentes descritores e classificador KNN (k = 9).

	KNN, k = 9							
	Brodatz		Outex		Vistex		Usptex	
	melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>		melhor <i>i</i>	
SF+LBP	90.90 (2.30)	1	78.09 (2.47)	5	94.79 (1.99)	2	77.18 (1.80)	5
LBP	90.90(1.67)	-	73.38 (2.75)	-	93.17 (3.98)	-	71.55 (2.65)	-
ganho	0.00	=	4.71	↑	1.62	↑	5.63	↑
SF+Histogram	10.00 (1.49)	4	27.57 (3.70)	5	20.95 (4.09)	1	10.73 (1.77)	5
Histogram	22.43(2.18)	-	23.16 (3.07)	-	32.29 (5.33)	-	12.26 (1.80)	-
ganho	-12.43	↓	4.41	↑	-11.34	↓	-1.53	↓
SF+GLCM	83.69 (2.18)	5	70.59 (3.49)	5	79.86 (3.03)	5	62.78 (4.09)	5
GLCM	79.55(2.75)	-	65.22 (4.60)	-	75.93 (5.64)	-	53.23 (3.12)	-
ganho	4.14	↑	5.37	↑	3.94	↑	9.55	↑
SF+GLDM	76.31 (2.72)	1	64.26 (4.89)	2	65.39 (5.23)	1	44.55 (2.54)	1
GLDM	65.41(4.19)	-	40.96 (2.43)	-	49.42 (3.67)	-	28.53 (2.92)	-
ganho	10.90	↑	23.31	↑	15.97	↑	16.01	↑
SF+Fourier	79.73 (2.51)	1	67.06 (3.43)	3	74.54 (4.00)	1	55.24 (1.98)	1
Fourier	79.64(2.92)	-	65.96 (3.27)	-	75.12 (3.89)	-	53.66 (1.92)	-
ganho	0.09	↑	1.10	↑	-0.58	↓	1.57	↑
SF+Gabor	85.23 (2.13)	1	70.44 (2.58)	2	81.25 (2.39)	2	66.71 (3.90)	1
Gabor	86.22(2.65)	-	70.81 (3.22)	-	81.48 (3.82)	-	65.27 (3.90)	-
ganho	-0.99	↓	-0.37	↓	-0.23	↓	1.44	↑
SF+Fractal	59.73 (2.13)	3	44.78 (4.83)	5	54.75 (4.13)	4	34.21 (3.21)	5
Fractal	45.14(5.58)	-	33.24 (3.28)	-	43.06 (2.93)	-	20.24 (3.08)	-
ganho	14.59	↑	11.54	↑	11.69	↑	13.96	↑

Fonte: Elaborada pelo autor.

Tabela 33 – São apresentadas as taxas de sucesso com KNN, $k = 3$ a partir das imagens transformadas e não transformadas pelo método EDT.

	KNN, $k = 3$							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
EDT+LBP	95.23 (1.16)	146	82.87 (2.92)	54	95.49 (3.15)	113	78.58 (1.30)	64
LBP	93.42(1.75)	-	73.24 (3.22)	-	96.06 (2.96)	-	72.16 (1.74)	-
ganho	1.80	↑	9.63	↑	-0.58	↓	6.41	↑
EDT+Histogram	36.85 (3.98)	111	36.54 (3.57)	66	41.44 (4.12)	95	18.06 (2.12)	140
Histogram	26.22(2.80)	-	22.65 (2.96)	-	34.95 (5.47)	-	12.26 (1.41)	-
ganho	10.63	↑	13.90	↑	6.48	↑	5.80	↑
EDT+GLCM	90.09 (2.82)	146	74.56 (2.33)	64	85.76 (4.50)	31	63.66 (4.48)	145
GLCM	87.03(2.59)	-	70.00 (5.48)	-	84.03 (3.25)	-	60.08 (2.62)	-
ganho	3.06	↑	4.56	↑	1.74	↑	3.58	↑
EDT+GLDM	75.95 (2.51)	77	60.44 (3.89)	46	63.77 (6.24)	37	35.91 (2.70)	69
GLDM	74.14(3.63)	-	47.06 (2.66)	-	56.13 (3.95)	-	31.98 (2.40)	-
ganho	1.80	↑	13.38	↑	7.64	↑	3.93	↑
EDT+Fourier	81.80 (4.73)	101	69.93 (2.77)	54	75.35 (3.79)	97	47.56 (2.68)	127
Fourier	84.41(2.69)	-	66.69 (3.16)	-	79.17 (4.28)	-	53.23 (3.00)	-
ganho	-2.61	↓	3.24	↑	-3.82	↓	-5.67	↓
EDT+Gabor	88.29 (3.95)	45	77.87 (2.81)	54	86.92 (4.01)	48	61.91 (2.42)	110
Gabor	89.37(2.07)	-	70.88 (3.01)	-	86.34 (2.76)	-	66.80 (2.25)	-
ganho	-1.08	↓	6.99	↑	0.58	↑	-4.89	↓
EDT+Fractal	51.53 (4.71)	76	48.38 (2.83)	43	45.83 (5.12)	145	22.95 (1.62)	90
Fractal	48.83(3.70)	-	40.51 (3.76)	-	47.11 (4.74)	-	23.21 (2.58)	-
ganho	2.70	↑	7.87	↑	-1.27	↓	-0.26	↓

Fonte: Elaborada pelo autor.

A.6 Transformada de Distância Euclidiana

Tabela 34 – São apresentadas as taxas de sucesso com KNN, $k = 5$ a partir das imagens transformadas e não transformadas pelo método EDT.

	KNN, $k = 5$							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
EDT+LBP	94.59 (2.75)	149	83.82 (3.00)	49	94.33 (2.86)	39	78.18 (3.22)	68
LBP	92.79(1.41)	-	74.41 (2.92)	-	94.21 (3.55)	-	73.17 (2.00)	-
ganho	1.80	↑	9.41	↑	0.12	↑	5.02	↑
EDT+Histogram	34.23 (3.10)	125	35.88 (4.42)	66	39.93 (4.72)	101	17.93 (2.15)	134
Histogram	25.41(4.18)	-	24.49 (3.06)	-	33.33 (2.91)	-	12.83 (0.99)	-
ganho	8.83	↑	11.40	↑	6.60	↑	5.10	↑
EDT+GLCM	88.02 (1.94)	77	72.94 (3.73)	66	83.45 (4.93)	95	61.69 (3.57)	145
GLCM	84.14(2.37)	-	68.60 (4.89)	-	81.94 (3.62)	-	58.42 (2.92)	-
ganho	3.87	↑	4.34	↑	1.50	↑	3.27	↑
EDT+GLDM	72.16 (2.93)	76	59.26 (3.36)	42	59.72 (6.76)	37	34.95 (2.09)	113
GLDM	69.91(4.10)	-	45.15 (1.44)	-	54.51 (4.71)	-	30.85 (1.60)	-
ganho	2.25	↑	14.12	↑	5.21	↑	4.10	↑
EDT+Fourier	80.81 (3.49)	105	70.44 (4.27)	44	73.96 (3.93)	103	47.77 (2.19)	126
Fourier	83.78(1.85)	-	66.84 (3.74)	-	78.59 (3.55)	-	54.62 (2.54)	-
ganho	-2.97	↓	3.60	↑	-4.63	↓	-6.85	↓
EDT+Gabor	87.39 (2.59)	80	78.46 (3.95)	54	85.53 (3.57)	28	62.78 (2.85)	109
Gabor	88.11(3.12)	-	70.81 (3.47)	-	85.07 (4.42)	-	67.10 (2.89)	-
ganho	-0.72	↓	7.65	↑	0.46	↑	-4.32	↓
EDT+Fractal	49.01 (5.22)	77	47.50 (2.53)	44	45.60 (4.73)	63	22.47 (1.97)	90
Fractal	47.84(3.30)	-	37.79 (3.03)	-	45.37 (3.11)	-	22.69 (2.93)	-
ganho	1.17	↑	9.71	↑	0.23	↑	-0.22	↓

Fonte: Elaborada pelo autor.

Tabela 35 – São apresentadas as taxas de sucesso com KNN, $k = 7$ a partir das imagens transformadas e não transformadas pelo método EDT.

	KNN, $k = 7$							
	Brodatz		Outex		Vistex		Usptex	
	melhor i		melhor i		melhor i		melhor i	
EDT+LBP	92.52 (1.80)	137	82.94 (3.41)	47	93.29 (3.21)	32	77.97 (3.09)	64
LBP	91.89(1.85)	-	74.04 (3.20)	-	94.44 (3.28)	-	72.43 (2.49)	-
ganho	0.63	↑	8.90	↑	-1.16	↓	5.54	↑
EDT+Histogram	32.52 (2.29)	113	33.38 (3.11)	54	39.00 (4.74)	95	17.36 (1.91)	136
Histogram	24.59(3.82)	-	24.71 (4.15)	-	33.56 (5.13)	-	11.91 (1.56)	-
ganho	7.93	↑	8.68	↑	5.44	↑	5.45	↑
EDT+GLCM	85.32 (2.82)	146	71.25 (3.71)	67	81.37 (4.21)	114	59.55 (2.82)	145
GLCM	81.71(2.55)	-	66.91 (3.83)	-	78.70 (3.86)	-	55.72 (4.42)	-
ganho	3.60	↑	4.34	↑	2.66	↑	3.84	↑
EDT+GLDM	69.64 (2.69)	78	57.87 (2.86)	44	56.71 (6.66)	36	34.64 (2.72)	76
GLDM	67.75(3.42)	-	41.99 (1.97)	-	51.16 (4.84)	-	28.97 (2.43)	-
ganho	1.89	↑	15.88	↑	5.56	↑	5.67	↑
EDT+Fourier	80.00 (3.65)	105	70.44 (4.51)	48	73.03 (3.60)	90	47.34 (2.86)	124
Fourier	81.44(2.26)	-	65.96 (3.67)	-	76.97 (3.68)	-	53.80 (1.92)	-
ganho	-1.44	↓	4.49	↑	-3.94	↓	-6.46	↓
EDT+Gabor	86.31 (3.29)	80	78.24 (2.77)	48	84.72 (5.44)	41	61.08 (2.22)	118
Gabor	87.12(2.40)	-	70.51 (2.83)	-	83.10 (2.72)	-	66.62 (3.63)	-
ganho	-0.81	↓	7.72	↑	1.62	↑	-5.54	↓
EDT+Fractal	46.58 (3.94)	76	47.57 (3.10)	43	44.44 (3.88)	63	22.03 (2.22)	106
Fractal	47.03(3.42)	-	34.63 (3.28)	-	44.91 (2.62)	-	21.25 (3.13)	-
ganho	-0.45	↓	12.94	↑	-0.46	↓	0.79	↑

Fonte: Elaborada pelo autor.

Tabela 36 – São apresentadas as taxas de sucesso com KNN, $k = 9$ a partir das imagens transformadas e não transformadas pelo método EDT.

	KNN, $k = 9$							
	Brodatz		Outex		Vistex		Usptex	
		melhor i		melhor i		melhor i		melhor i
EDT+LBP	90.99 (1.81)	110	82.65 (1.42)	55	91.90 (3.02)	114	76.88 (3.09)	68
LBP	90.90(1.67)	-	73.38 (2.75)	-	93.17 (3.98)	-	71.55 (2.65)	-
ganho	0.09	↑	9.26	↑	-1.27	↓	5.32	↑
EDT+Histogram	31.26 (2.59)	113	34.04 (4.10)	60	38.54 (5.24)	99	17.41 (1.35)	135
Histogram	22.43(2.18)	-	23.16 (3.07)	-	32.29 (5.33)	-	12.26 (1.80)	-
ganho	8.83	↑	10.88	↑	6.25	↑	5.15	↑
EDT+GLCM	82.88 (1.96)	90	70.29 (4.67)	61	80.21 (3.48)	99	57.07 (2.65)	145
GLCM	79.55(2.75)	-	65.22 (4.60)	-	75.93 (5.64)	-	53.23 (3.12)	-
ganho	3.33	↑	5.07	↑	4.28	↑	3.84	↑
EDT+GLDM	66.58 (4.42)	74	58.24 (2.47)	45	55.09 (3.10)	19	33.86 (2.04)	74
GLDM	65.41(4.19)	-	40.96 (2.43)	-	49.42 (3.67)	-	28.53 (2.92)	-
ganho	1.17	↑	17.28	↑	5.67	↑	5.32	↑
EDT+Fourier	77.21 (2.72)	74	69.49 (6.08)	48	72.45 (4.29)	91	46.68 (2.88)	123
Fourier	79.64(2.92)	-	65.96 (3.27)	-	75.12 (3.89)	-	53.66 (1.92)	-
ganho	-2.43	↓	3.53	↑	-2.66	↓	-6.98	↓
EDT+Gabor	84.50 (3.79)	148	77.35 (2.60)	47	83.10 (4.35)	56	60.30 (3.53)	129
Gabor	86.22(2.65)	-	70.81 (3.22)	-	81.48 (3.82)	-	65.27 (3.90)	-
ganho	-1.71	↓	6.54	↑	1.62	↑	-4.97	↓
EDT+Fractal	44.95 (4.91)	74	46.47 (3.02)	43	43.52 (5.22)	135	21.47 (2.24)	99
Fractal	45.14(5.58)	-	33.24 (3.28)	-	43.06 (2.93)	-	20.24 (3.08)	-
ganho	-0.18	↓	13.24	↑	0.46	↑	1.22	↑

Fonte: Elaborada pelo autor.