

UNIVERSIDADE ESTADUAL DE PONTA GROSSA
MESTRADO EM COMPUTAÇÃO APLICADA

LUIZ GUSTAVO BARROS

**IMPACTO DA ANÁLISE DA NITIDEZ EM MÉTODOS DE CLASSIFICAÇÃO DE
IMAGENS DE MADEIRA**

PONTA GROSSA

2013

LUIZ GUSTAVO BARROS

**IMPACTO DA ANÁLISE DA NITIDEZ EM MÉTODOS DE CLASSIFICAÇÃO DE
IMAGENS DE MADEIRA**

Dissertação apresentada ao Programa de Pós-Graduação em Computação Aplicada, curso de Mestrado em Computação Aplicada da Universidade Estadual de Ponta Grossa, como requisito parcial para obtenção do título de Mestre em Computação Aplicada.

Orientação: Prof. Dr. Alceu de Souza Britto Junior

Co-Orientador: Prof. Dr. José Carlos Ferreira da Rocha

PONTA GROSSA

2013

Ficha Catalográfica
Elaborada pelo Setor de Tratamento da Informação BICEN/UEPG

Barros, Luiz Gustavo
B277 Impacto da análise da nitidez em
 métodos de classificação de imagens de
 madeira/ Luiz Gustavo Barros. Ponta
 Grossa, 2013.
 54f.

 Dissertação (Mestrado em Computação
 Aplicada - Área de Concentração:
 Computação para Tecnologias em
 Agricultura), Universidade Estadual de
 Ponta Grossa.
 Orientador: Prof. Dr. Alceu de Souza
 Britto Junior.
 Co-Orientador: Prof. Dr. José Carlos
 Ferreira da Rocha.

 1.Análise de nitidez. 2.Visão
 computacional. 3.Classificação de imagens.
 I.Britto Junior, Alceu de Souza. II.
 Rocha, José Carlos Ferreira da. III.
 Universidade Estadual de Ponta Grossa.
 Mestrado em Computação Aplicada. IV. T.

CDD: 006.6


TERMO DE APROVAÇÃO

Luiz Gustavo Barros

**“IMPACTO DA ANÁLISE DE NITIDEZ EM MÉTODOS DE CLASSIFICAÇÃO DE
IMAGENS DE MADEIRA”.**

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre no Programa de Pós-Graduação em Computação Aplicada da Universidade Estadual de Ponta Grossa, pela seguinte banca examinadora:

Orientador:



Dr. Alceu de Souza Britto Junior
UEPG



Dr. Ariangelo Hauer Dias
UEPG



Dr. Jacques Facon
PUC PR

Ponta Grossa, 22 de agosto de 2013.

AGRADECIMENTOS

Ao criador, Deus, que nos deu o dom da vida, acima de tudo.

A minha família, pela compreensão, pelo apoio e pela educação e conselhos dados durante toda a minha vida.

Aos meus pais, Luiz Antonio e Ione pelo apoio incondicional.

Agradeço a Taiana, minha namorada, pelo incentivo, paciência e compreensão.

Ao meu orientador Professor Alceu, pela confiança depositada em mim e por todo o auxílio prestado na elaboração de todas as fases desse trabalho bem como pela introdução sobre a temática a ser abordada e o processo de construção do conhecimento.

Aos professores do Mestrado em Computação Aplicada por todo o conhecimento que foi ministrado dentro e fora das salas de aula durante toda a duração do curso.

Ao Professor José Carlos e ao colegiado do curso por terem aceitado o pedido de prorrogação de prazo desse trabalho.

A Universidade Estadual de Ponta Grossa, instituição que me proporcionou a realização desse curso e da qual me orgulho de fazer parte do seu quadro funcional.

E a todos os demais que ajudaram de alguma forma para a conclusão desse trabalho.

RESUMO

Imagens adquiridas em campo, com câmeras comuns, tendem a possuir uma qualidade inferior se comparadas com as adquiridas em laboratório, incluindo ruídos e áreas pouco nítidas. Partindo dessa premissa, nesse trabalho foi proposta uma metodologia para a análise de nitidez em imagens de madeira para analisar seu impacto na classificação das mesmas. Para avaliar essa proposta, foi utilizada uma base de dados de imagens de madeira e extraídas características de cor e textura através dos métodos LBP Uniforme e RGB, respectivamente. O método Tenengrad foi utilizado para avaliar a nitidez das imagens e através dele as imagens foram classificadas alta e baixa nitidez. Foram elaborados cenários para testar o impacto da análise de nitidez e verificar de que forma a mesma contribui com a taxa de acerto.

Palavras-chave: Análise de nitidez, visão computacional, classificação de imagens

ABSTRACT

Images acquired in the field with ordinary cameras, tend to have a lower quality compared with those obtained in the laboratory, including noise and unclear areas. This paper proposes a methodology for the analysis of sharpness in wood images of wood to analyze its impact on their classification. To evaluate this proposal, a database of wood images was used and each sample has extracted its color and texture characteristics using uniform local binary pattern and RGB color model methods, respectively. The Tenengrad method was used to evaluate the image sharpness and then the images were classified as high or low sharpness. Scenarios were developed to test the impact of the analysis of sharpness and check how it contributes to the hit rate.

Keywords: sharpness, computer vision, image classification

LISTA DE FIGURAS

Figura 1 - Imagem de espécie de madeira	13
Figura 2 – Cubo RGB.....	21
Figura 3 – Sobreposição das cores primárias	22
Figura 4– Amostra de imagem da base de dados	22
Figura 5 – Resultado da com o algoritmo LBP	23
Figura 6 – Operador LBP	23
Figura 7 – Exemplos de vizinhança do LBP	24
Figura 8 – Imagem com mascara Sx do Operador Sobel	27
Figura 9 - Imagem com mascara Sy do Operador Sobel.....	27
Figura 10 - Amostra da base de dados.....	31
Figura 11 - Divisão da amostra em janelas.....	32
Figura 12 - Imagens para teste do algoritmo de nitidez	34
Figura 13 – Amostra da base de dados	39
Figura 14 – Amostra da base de dados com divisão em janelas e índice de nitidez	40
Figura 15 – Taxa de acerto dos métodos	46
Figura 16 - Taxa de acerto dos métodos desconsiderando imagens de baixa nitidez	47
Figura 17 - Taxa de acerto dos métodos com voto majoritário	47
Figura 18- Taxa de acerto dos métodos com voto majoritário desconsiderando imagens de baixa nitidez.....	48
Figura 19 – Impacto da análise de nitidez nos cenários propostos.....	49

LISTA DE TABELAS

Tabela 1 - Resumo dos métodos apresentados	20
Tabela 2 - Banco de dados de imagens	30
Tabela 3 - Quantidade de janelas por cenário.....	33
Tabela 4 - Divisão das amostras	33
Tabela 5 – Resumo das técnicas antes da classificação.....	36
Tabela 6 - Resumo das técnicas após a classificação	37
Tabela 7 – Valores de nitidez para a amostra	40
Tabela 8 – Percentual de janelas com baixa nitidez	41
Tabela 9 – Taxa de acerto no cenário de amostra inteira	41
Tabela 10 - Taxa de acerto das combinações no cenário de amostra inteira.....	42
Tabela 11 - Taxa de acerto no cenário com divisão em 12 janelas por amostra	42
Tabela 12 - Taxa de acerto das combinações no cenário com divisão em 12 janelas por amostra	43
Tabela 13 - Taxa de acerto no cenário com divisão em 24 janelas por amostra	43
Tabela 15 - Taxa de acerto no cenário com divisão em 36 janelas por amostra	44
Tabela 16 - Taxa de acerto das combinações no cenário com divisão em 36 janelas por amostra	45
Tabela 17 - Taxa de acerto no cenário com divisão em 48 janelas por amostra	45
Tabela 18 - Taxa de acerto das combinações no cenário com divisão em 48 janelas por amostra	45

LISTA DE EQUAÇÕES

Equação 1 - Máscaras do operador Sobel.....	26
Equação 2 - Magnitude do gradiente.....	26
Equação 3 - Medida de foco de Tenengrad	27
Equação 4 – Definição de alta nitidez	35
Equação 5 – Definição de baixa nitidez	35

LISTA DE SIGLAS

GLCM	<i>Gray-Level Co-occurrence Matrices</i>
RNA	Rede Neural Artificial
MLP	<i>Multi Layer Perceptron</i>
SVD	<i>Single value decomposition</i>
RGB	<i>Red, Green, Blue</i>
NSGA	<i>Non-Dominated Sorting Algorithm</i>
SVM	<i>Support Vector Machines</i>
HSV	<i>Hue, Saturation, Value</i>
LRE	<i>Long run emphasis</i>
LBP	<i>Local Binary Pattern</i>
LBPU	<i>Local Binary Pattern – Uniform</i>
RGB	<i>Red, Green, blue</i>
HSV	<i>Hue, saturation, value</i>
HSI	<i>Hue, saturation, intensity</i>

SUMÁRIO

1 - Introdução.....	12
1.1 – Definição do problema.....	12
1.2 - Motivação	12
1.3 - Objetivos.....	13
1.4 - Resultados Esperados	14
1.5 – Estrutura do Trabalho	14
2 – Revisão da Literatura.....	15
2.1 – Métodos de classificação de madeira.....	15
2.2 - Métodos de análise de nitidez.....	18
2.3 - Extração de características.....	20
2.3.1 – Cor	20
2.3.2 – LBP - <i>Local Binary Pattern</i>	22
2.3.3 – LBP Uniforme	24
2.4 – Técnicas de análise de nitidez.....	25
3 – Materiais e Métodos	29
3.1 – Divisão das amostras.....	30
3.2 - Extração e combinação de características.....	33
3.3 - Cálculo da nitidez	34
3.4 – Classificação através de rede neural.....	35
3.5 - Resumo das técnicas	36
4 – Resultados experimentais	38
4.1 – Análise de nitidez	39
4.2 – Uso da amostra inteira.....	41
4.3 – Cenário com divisão em 12 janelas por amostra.....	42

4.4 – Cenário com divisão em 24 janelas por amostra.....	43
4.5 – Cenário com divisão em 36 janelas por amostra.....	44
4.6 – Cenário com divisão em 48 janelas por amostra.....	45
4.7 - Análise dos resultados.....	45
5 – Conclusão e trabalhos futuros.....	50
6 – Referências	51

1 - Introdução

O avanço tecnológico de hardware e software tem viabilizado o uso de técnicas de Visão Computacional e Reconhecimento de Padrões nas mais variadas aplicações. A cada dia novas soluções baseadas na interpretação automática de imagens e/ou vídeos são disponibilizadas no mercado. Neste contexto, muitos esforços têm sido feitos na busca da automatização do processo de classificação de madeira.

1.1 – Definição do problema

É importante diferenciar espécies de madeira para avaliar suas diferentes características que podem implicar no resultado de produtos no caso da indústria de manufaturados, ou na sua resistência a forças de tração e compressão no caso da construção civil (TOU *et al.*, 2007). Outro propósito para a identificação de madeira é o combate a fraudes nas quais vários tipos de madeira de aparência similar, porém mais baratos, são mesclados de forma a aumentar a margem de lucro na comercialização (KHALID *et al.*, 2008).

1.2 - Motivação

A identificação de uma árvore pode ser feita de forma simples ao examinar suas flores, folhas e frutos. Entretanto, após o seu corte essa identificação se torna difícil e é feita apenas com base no padrão apresentado pelas suas fibras e casca (BREMANANTH *et al.*, 2009).

A utilização de visão computacional para reconhecimento de espécies de madeira vem sendo utilizada desde a década de 1980, com o propósito de inspeção para determinar a qualidade da madeira e a presença de defeitos (KHALID *et al.*, 2008).

O foco deste trabalho é utilizar imagens obtidas com câmeras comuns para fazer a classificação. Realizar a análise de imagens adquiridas em campo, com equipamentos comuns, sem a utilização de equipamentos sofisticados que exigem um laboratório especial. Desta forma, existe a possibilidade de que tais imagens possuam um prejuízo de qualidade na nitidez. Assim, parte-se da hipótese que a análise prévia de nitidez pode aumentar a taxa de acerto na classificação das espécies de amostras de madeira.

Dentre as contribuições esperadas está a avaliação do impacto da análise da nitidez no processo de classificação e a determinação se essa análise é relevante ou não para melhorar os resultados da classificação da madeira. Além disto, será possível disponibilizar um novo método de classificação de madeira que possa ser utilizado em campo e de baixo custo.

Na Figura 1, é possível verificar uma falta de foco na região inferior direita causado pela captura da amostra realizada com equipamentos comuns em campo. É possível perceber que a região central da imagem possui uma maior nitidez, sendo essa a área de interesse para ser utilizada na classificação da amostra. Essa figura foi retirada da base de dados utilizada nesse trabalho.




Figura 1 - Imagem de espécie de madeira

1.3 - Objetivos

Essa pesquisa tem como objetivo medir o impacto da análise de nitidez em imagens de tábuas de madeira na classificação da respectiva espécie vegetal. Portanto, elaborou-se um método para a análise de imagens, dividir cada imagem em zonas e calcular o índice de nitidez de cada zona e definir quais zonas serão utilizadas para a classificação. Após definida quais as zonas que serão utilizadas, será necessário definir um método de classificação das amostras e comparar o índice de acerto na classificação com e sem a

análise de nitidez. Com isso, será proposta uma técnica para análise das imagens e será desenvolvida uma ferramenta para realizar a manipulação das imagens e possibilitar a execução dos testes.

1.4 - Resultados Esperados

Os resultados esperados provenientes dessa pesquisa são a criação de uma ferramenta que avalie as imagens obtidas e determine de qual espécie vegetal a imagem pertence. Além disto, espera-se demonstrar qual o impacto da análise de nitidez no processo de classificação proposto.

1.5 – Estrutura do Trabalho

Este trabalho foi dividido em cinco capítulos. O primeiro capítulo é referente a introdução. O capítulo 2 apresenta uma revisão da literatura, incluindo uma visão geral do estado da arte. O terceiro capítulo apresenta a metodologia empregada nesse estudo. O capítulo 4 detalha os resultados dos experimentos realizados e o capítulo 5 apresenta as conclusões e discussão do trabalho.

2 – Revisão da Literatura

Este capítulo apresenta os principais trabalhos relacionados ao tema desse projeto e busca verificar as técnicas utilizadas no reconhecimento de imagens de madeira, sua classificação e como é realizada a avaliação da nitidez de imagens.

2.1 – Métodos de classificação de madeira

A utilização da visão computacional para o reconhecimento de imagens de madeira emprega como características relevantes as de cor e textura da imagem. Cada espécie contém um padrão único de textura seja em sua casca ou no plano de corte da madeira.

Khalid *et al.* (KHALID *et al.*, 2008) propuseram um sistema de reconhecimento de espécies de madeira. Foram utilizadas imagens adquiridas em laboratório, utilizando câmeras monocromáticas de padrão industrial e lentes e iluminação apropriadas. O pré-processamento consistiu em um filtro passa-alta e ajustes de contraste e equalização do histograma da imagem. Foi aplicado o método GLCM – *Gray-Level Co-occurrence Matrices* para a extração das características de segundo momento angular, contraste, correlação, entropia e momento diferencial inverso. Esses atributos foram aplicados em uma RNA – Rede neural artificial, que classificou as 20 espécies diferentes. As taxas de acerto chegaram a 95%.

Em (BREMANANTH *et al.*, 2009) os autores apresentam outro sistema de reconhecimento de espécies de madeira. Inicialmente, foi realizado um pré-processamento para a conversão das imagens coloridas para tons de cinza e redimensionamento para um tamanho padrão. A análise de textura foi utilizada para a extração de características únicas de cada imagem e o método utilizado foi o GLCM. Com o GLCM foram extraídas as características de energia, entropia, homogeneidade, momento diferencial inverso e segundo momento angular. O GLCM é gerado acumulando o número total de *pixels* cinzas pares da imagem. Na classificação foi utilizada a co-relação da textura, através do GLCM, e as taxas de acerto foram satisfatórias para a classificação de 10 tipos de espécies de madeira.

No trabalho de (TOU *et al.*, 2007), é explorada a possibilidade de desenvolver um sistema capaz de reconhecer tipos de madeira baseado em sua anatomia utilizando redes

neurais artificiais (RNA). O método GLCM foi utilizado para a extração das características e a rede neural do tipo MLP – *Multi Layer Perceptron*. A matriz GLCM foi gerada em quadro direções (0° , 45° , 90° , 135°) e as características de textura extraídas foram contraste, co-relação, energia, homogeneidade e entropia. O contraste é utilizado para medir as variações locais da imagem, a co-relação mede a probabilidade da ocorrência de um par específico de pixels, energia pode ser traduzida como a uniformidade do segundo momento angular que é a soma do quadrado dos elementos da matriz GLCM e homogeneidade é a medida da distribuição dos elementos na matriz GLCM relacionando a diagonal e as medidas de entropia. Assim, com as 5 características analisadas nas quatro direções obteve-se 20 características para serem extraídas de cada imagem. No primeiro experimento, essas 20 características foram introduzidas em uma RNA que utilizou 20 neurônios na camada oculta e cinco neurônios na camada de saída e obteve 72% de precisão, sendo que para duas espécies obtiveram 100%. No segundo experimento, a diferença foi que a característica de energia foi retirada nas quatro direções, resultando em 16 neurônios na camada de entrada. Os resultados foram de 60% e uma espécie obteve o reconhecimento de 100% das amostras. Esses experimentos mostraram que as técnicas GLCM e MLP são eficientes para o reconhecimento de madeira. Outra conclusão desse trabalho foi que a característica de entropia não se mostrou muito útil para o reconhecimento das amostras.

Em Tou *et al.* (TOU *et al.*, 2009) é proposto um estudo comparativo de técnicas de classificação de textura para o reconhecimento de madeira, continuando o trabalho proposto em (TOU *et al.*, 2007). Os testes foram realizados para a identificação de seis espécies, utilizando 100 imagens de cada espécie, das quais 90% utilizadas para treinamento e 10% para testes. O classificador escolhido foi o classificador supervisionado dos k vizinhos mais próximos – k-NN. Cinco experimentos foram realizados, utilizando como método de extração de características GLCM, filtros Gabor, combinação GLCM e Gabor, matriz de covariância e *verification-based recognition*. No experimento usando atributos GLCM a melhor taxa de acerto foi de 76,67% e foram extraídas as características de contraste, correlação, energia, entropia e homogeneidade, nas oito direções, para garantir invariância de rotação. No experimento usando filtros Gabor, o número de características extraídas foi reduzido através do método SVD – *single value decomposition*, e obteve uma taxa de

acerto de 73,33%. Na combinação dos métodos GLCM e filtro Gabor a taxa obtida foi de 76,67%. A matriz de covariância foi gerada utilizando os filtros Gabor e nesse método foi 85% de acerto, a melhor taxa entre os métodos abordados nesse estudo. No último experimento onde foi empregado o método *verification-based recognition* usando quatro matrizes de co-ocorrência com distância 1 pixel em oito tons de cinza, foi obtido 78,33% de taxa de acerto.

Em (OLIVEIRA, 2008), foi proposto um método para a detecção de defeitos em tábuas de madeira de Pinus utilizando visão computacional. A otimização do corte de matéria necessita da detecção dos defeitos para maximizar a produção dessa área. O método foi composto por duas câmeras do tipo *line scan*, computador, iluminação baseada em *leds* e um transportador. As tábuas percorrem o transportador e a imagem de ambas as faces são capturadas pelas câmeras, que estão sincronizadas com a velocidade do transportador. As imagens são processadas utilizando a extração de características de dois conjuntos principais. O primeiro é baseado em características de cor e utiliza histogramas de percentis cada canal de cor *Red*, *Green* e *Blue* do sistema RGB. Foram extraídas 10 características de percentis para cada um dos três canais. O segundo conjunto, relativo à textura das imagens, emprega o método da matriz de co-ocorrência (GLCM) que representa a relação entre os pixels dentro de uma região. Foram escolhidas as características de contraste, energia, entropia e co-relação. Para minimizar o impacto da seleção incorreta de características, como características co-relacionadas e interdependências, foi utilizado o algoritmo genético multi-objetivo NSGA - *Non-Dominated Sorting Algorithm*. Na fase de classificação foram utilizados os paradigmas de aprendizagem de máquina SVM – *Support Vector Machines* e RNA do tipo MLP. Utilizando as características de cor, a melhor taxa de acerto com a RNA foi de 98,1% e com a SVM a taxa foi de 98,7%. Obtendo as características através da matriz de co-ocorrência, as melhores taxas foram de 97,5% e 98,0 para RNA e SVM, respectivamente. Foi possível observar que tanto as características de cor quanto as características de textura apresentaram resultados similares.

Em (YU *et al.*, 2009a) é apresentado um método de recuperação de imagens de madeira que integra as características de cor, textura e informação espacial, baseado nas técnicas de extração de características: HSV, GLCM, modelos LRE, *wavelets* e algoritmos fractais. Destas técnicas foram extraídas as características: matiz, saturação, valor,

contraste, segundo momento angular, soma das variâncias, LRE, dimensão fractal e proporção wavelet de energia horizontal. Para as características relativas a cor, usou-se o modelo HSV – *Hue, Saturation, Value*, e através do método GLCM foram extraídos contraste, segundo momento angular e soma das variâncias. No aspecto da textura, foi calculado o LRE - *long run emphasis*, através das técnicas de wavelet foi calculada a proporção de energia da baixa frequência horizontal e por fim foi obtida a dimensão fractal. Foram realizados três experimentos. No primeiro somente as características do modelo HSV foram utilizadas, e propuseram um método de divisão espacial não igualitário descrito em (YU *et al.*, 2009b), no qual o canal H é dividido em nove blocos, e os canais S e V em quatro blocos cada. No final, o vetor de características foi transformado em um histograma unidimensional de 164 elementos para simplificar a complexidade computacional. No segundo experimento foram usadas características de textura. Concluiu-se que o uso de características de cor, ou de textura isoladas não foram suficientes para um resultado satisfatório, o que levou ao último experimento que combinou ambas características. Após o terceiro experimento, concluiu que para o reconhecimento de imagens de madeira, a cor e a textura são as características visuais mais importantes e que apenas uma das mesmas não pode construir uma ferramenta de reconhecimento que tenha resultado satisfatório, e que para um bom índice de precisão deve-se combinar tanto atributos de cor quanto de textura.

2.2 - Métodos de análise de nitidez

Em (PECH-PACHECO *et al.*, 2000) a avaliação de nitidez em imagens é apresentada. A nitidez se refere a clareza de detalhes e é composta pela capacidade da percepção humana e fórmulas matemáticas para dispositivos digitais. Assim, não se constitui tarefa trivial combinar aspectos subjetivos e objetivos para se obter uma avaliação de nitidez. Métricas para quantificar a nitidez fazem análise das bordas dos objetos presentes nas imagens através de algoritmos de detecção de bordas. Utilizando medidas de foco Tenengrad, uma imagem bem focada deve apresentar bordas nítidas. Assim, o uso de imagens de gradiente podem ser utilizadas como um instrumento para determinar uma medida confiável de foco.

Em (ANAICE, 2010) os autores propõem quatro métricas de nitidez: Tenengrad e variância do operador Sobel – baseadas no cálculo do gradiente e Operador Laplaciano e Variância do Operador Laplaciano - baseadas no cálculo do Laplaciano. Essas quatro

métricas foram usadas no estudo juntamente com os métodos *No Reference Blur Metric G_x* , *No Reference Blur Metric G_y* e *Global Sharpness*. Para se comparar cada métrica é necessário usar de artifícios matemáticos para o estudo da nitidez. Existe uma dificuldade em atribuir um valor que represente quão nítida é uma imagem, visto que essa medida pode ser subjetiva, porém pode-se através da degradação artificial da máscara da média estabelecer uma escala de nitidez relativa. Essa escala não se aplica a degradações reais que são mais complexas, porém pode ser utilizada com ponto inicial para o estudo de métricas em uma base com essa escala. O estudo se baseou em imagens simples nos quesitos contraste, conteúdo e fundo. As imagens foram geradas artificialmente. O uso de imagens reais foi evitado devido as mesmas serem complexas podendo ter diversos objetos diferenciados entre si, e tipos de fundo variados e heterogêneos em contraste e textura. A base foi composta com 15 imagens e para cada uma foi gerada máscaras onde as mesmas foram sendo borradas. No total foram utilizadas 105 imagens. O classificador utilizado foi o k-NN e foram executados dois experimentos sendo o primeiro para medir a nitidez e o outro para medir a falta de nitidez. De acordo com os testes, a métrica de Tenengrad foi a que obteve a melhor taxa de acerto com 81,25% para o reconhecimento das imagens que apresentavam total nitidez. Outra conclusão desse trabalho foi que a taxa de reconhecimento da falta de nitidez foi baixa, portanto o reconhecimento de nitidez foi o que obteve taxas mais promissoras.

A Tabela 1 apresenta um resumo dos métodos apresentados, levando em consideração os métodos de extração de características, os algoritmos classificadores, o tamanho da base de dados de imagens utilizada e a melhor taxa de acerto para cada um dos trabalhos apresentados nesse capítulo.

Pesquisa	Método de extração de características	Algoritmo classificador	Quantidade de imagens	Melhor taxa de acerto
KHALID <i>et al.</i>, 2008	GLCM	RNA	1949	95%
BREMANANTH <i>et al.</i>, 2009	GLCM	Fator de correlação	Não disponível	Não disponível
TOU <i>et al.</i>, 2007	GLCM	RNA	360	72%
TOU <i>et al.</i>, 2009	GLCM, filtros Gabor, combinação GLCM e	k-NN	600	85%

	Gabor, matriz de covariância e <i>verification-based recognition</i>			
OLIVEIRA, 2008	Cor, GLCM	MLP, SVM		98,7%
YU <i>et al.</i>, 2009	HSV, GLCM, modelos LRE, wavelets e algoritmos fractais.	Não disponível	100	Não disponível

Tabela 1 - Resumo dos métodos apresentados

2.3 - Extração de características

2.3.1 – Cor

Devido as diferenças de interpretação e da quantidade de variação de cores serem relativamente amplas, foram definidos modelos de cores, como o HSV, HSI e o RGB, sendo este último utilizado neste trabalho.

A percepção de imagens pela visão humana tem sido utilizada como base para sistemas de visão computacional, bem como para dispositivos como câmeras e monitores de vídeo. O olho humano responde a estímulos das cores vermelha - *red*, verde - *green* e azul - *blue*, tidas estas como primárias. A adição dessas cores permite a derivação de outras cores. O modelo RGB parte dessas premissas, tendo como base a teoria tricromática de Young-Helmholtz, que provou que todas as cores das frequências visíveis poderiam ser formadas a partir da adição das três cores primárias (HUNT, 2004). No modelo RGB, cada uma das cores primárias corresponde a um canal de cor.

O cubo RGB representa graficamente o modelo em um espaço de três dimensões. Nesse sólido, conforme a Figura 2, cada eixo representa a intensidade de cada cor primária. Cada aresta gera um plano com as cores secundárias, que são cores que possuem igual contribuição de duas cores primárias em sua máxima intensidade.




Figura 2 – Cubo RGB
Fonte: Adaptado de (RUSS, 2011)

Conforme a Figura 3 as cores secundárias são as combinações de: azul e verde resultando em ciano, vermelho e azul dando origem a cor magenta e, por fim, vermelho e verde tendo como resultado a cor amarela. Os dois vértices restantes do cubo representam as cores preta (ausência de cor) e branca (as três cores primárias em sua intensidade máxima). A diagonal entre os vértices branco e preto do cubo dão origem aos tons de cinza.




Figura 3 – Sobreposição das cores primárias

2.3.2 – LBP - *Local Binary Pattern*

O *LBP – Local Binary Pattern*, é um método que transforma uma imagem em um vetor ou uma imagem de valores de pixels inteiros que descrevem características de textura. As figuras 4 e 5 comparam uma imagem de entrada e a saída do método LBP. Esses valores que descrevem essas características são os que compõem o histograma e que são utilizados para análise.




Figura 4– Amostra de imagem da base de dados




Figura 5 – Resultado da com o algoritmo LBP

Wang e He (WANG, 1990) propuseram um modelo de análise de textura juntamente com uma unidade de textura, representada pelo elemento central e seus oito vizinhos sendo que cada um destes poderia ter três valores possíveis, sendo eles 0, 1 ou 2. Nessa vizinhança, portanto, teríamos 3^8 possibilidades de textura, totalizando 6561 possibilidades. Ojala *et al.* (OJALA *et al.*, 1996) propuseram a redução dos valores para apenas 0 e 1, com o mesmo tamanho de vizinhança, resultando em 2^8 possibilidades, reduzindo para 256 texturas possíveis.

O cálculo é feito através do valor da escala de cinza do *pixel* central, que é definido como o limiar. Os oito *pixels* vizinhos são convertidos nos valores entre zero e um, caso sejam menores ou maiores que o limiar, respectivamente. Os códigos formam um padrão binário relativo ao *pixel* central. Cada *pixel* de uma determinada imagem tem o seu valor do LBP obtido e assim pode ser feito um histograma dos padrões de textura para essa imagem.




Figura 6 – Operador LBP

Fonte: Adaptado de (AHONEN, 2006).

O estudo inicial propôs uma vizinhança de distância de 1 *pixel* em relação ao *pixel* central. Ojala *et al.* (OJALA *et al.*, 2002), deram continuidade ao método proposto e um modelo de distância variável em relação ao *pixel* central foi desenvolvido. Os valores dos tons de cinza a serem utilizados correspondem aos pixels delimitados por um círculo de raio R . As coordenadas do círculo que não coincidirem exatamente em um *pixel* são estimadas por interpolação bilinear. A Figura 7 exemplifica o processo da vizinhança do LBP.




Figura 7 – Exemplos de vizinhança do LBP

Fonte: (PIETIKÄINEN *et al.*, 2011)

2.3.3 – LBP Uniforme

Em (OJALA *et al.*, 2002) é proposta a definição de padrões uniformes, considerando o a quantidade de transições que ocorrem em cada padrão de textura. Esse valor de transição foi determinado como U . Os padrões 00000000 e 11111111 são os únicos que não apresentam transições, visto que todos os valores são idênticos. Os padrões que apresentam uma saída de 0 para 1 ou de 1 para 0, como, por exemplo, 00001000, apresentam $U = 2$. Os padrões restantes, que apresentam mais de uma troca de 0 para 1 ou vice-versa, possuem U igual ou maior do que quatro. Foram definidos como uniformes, todos os padrões de textura com $U \leq 2$. Assim, tomando como exemplo, os padrões 11111111 (nenhuma transição), 00011100 (duas transições) e 10000011 (2 transições) são uniformes, enquanto os padrões 11001011 (4 transições), 01010001 (6 transições) não são uniformes.

Sendo assim, 58 dos 256 padrões existentes são considerados uniformes. Esses padrões binários uniformes são propriedades fundamentais da textura e sua frequência pode exceder 90% (OJALA *et al.*, 2002). O histograma considera os 58 padrões uniformes e mais um valor para agrupar todos os outros valores não uniformes, totalizando 59 posições.

Por fim, utilizar padrões uniformes, ao invés de todos os padrões possíveis, pode produzir melhores resultados no reconhecimento e classificação em diversas aplicações (PIETIKÄINEN *et al.*, 2011), pois os padrões uniformes tendem a ser mais estáveis e menos suscetíveis a ruídos.

Além do LBP Uniforme, existem outros métodos derivados do método LBP, como o LBP invariante a rotação da imagem, dentre outros, elencados em (DOSHI, 2012). Ainda, é possível aplicar o LBP utilizando as características de cor da imagem, não limitando a análise da mesma em escala de cinza, conforme proposto em (MÄENPÄÄ, 2004) e também em (ZHU, 2010), o que por si só já proporciona uma combinação de propriedades de cor e textura. Estes métodos citados não serão objeto desse estudo.

2.4 – Técnicas de análise de nitidez

O foco de uma imagem determina sua qualidade, bem como desempenha um papel significativo em aplicações de visão computacional em diversas áreas, tais como fotografia digital, visão robótica e microscopia (WEE, 2006).

A percepção da nitidez de uma imagem está relacionada com a clareza de detalhes e as definições das bordas de uma imagem (CAVIEDES, 2002). A visão humana é capaz de perceber uma imagem com detalhes, e as áreas de baixa nitidez podem ser identificadas de forma relativamente fácil. Porém ao capturar essa imagem com dispositivos eletrônicos, essa tarefa não é trivial (VU, 2012), bem como alguns elementos da mesma podem não ficar claramente visíveis, contendo áreas desfocadas (CHOUDHURY, 2011). Assim, identificar essas áreas é uma tarefa necessária e que pode melhorar o reconhecimento dessas imagens através de técnicas computacionais.

Métricas de nitidez podem ser utilizadas como parâmetro para a aplicação de algoritmos de melhoria de nitidez, bem como podem ser também utilizadas para estimar o ruído ocasionado na nitidez de uma imagem por alguns algoritmos de compressão (FERZLI, 2009).

Imagens desfocadas, ou pouco nítidas, tendem a possuir menos informações do que imagens mais nítidas. A qualidade do foco de uma imagem afeta as bordas dos objetos de uma imagem. Uma imagem com bom foco deve possuir bordas bem definidas, assim, o uso de gradientes são instrumentos para determinar uma medida de foco (PECH-PACHECO *et al.*, 2000). O método Tenengrad, que é considerado um padrão de referência, além de ser um dos mais comuns (MAHMOOD *et al.*, 2011), estima a magnitude do gradiente em cada ponto da imagem e soma todas as magnitudes acima de um limiar T. O operador Sobel é utilizado como máscara para a obtenção do gradiente:

$$Sx = \begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{pmatrix} Sy = \begin{pmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{pmatrix}$$

Equação 1 - Máscaras do operador Sobel

A magnitude do gradiente em cada pixel é dada como:

$$S(x, y) = \sqrt{[Sx * I(x, y)]^2 + [Sy * I(x, y)]^2}$$

Equação 2 - Magnitude do gradiente

Sendo,

$I(x, y)$ a imagem de entrada em níveis de cinza

$Sx * I(x, y)$ a imagem aplicada ao operador Sobel para os valores de x

$Sy * I(x, y)$ a imagem aplicada ao operador Sobel aos valores de y.

A Figura 8 demonstra o resultado da máscara Sx do operador Sobel em uma imagem da base dados, enquanto a Figura 9 exhibe o resultado para a máscara Sy .



Figura 8 – Imagem com mascara Sx do Operador Sobel



Figura 9 - Imagem com mascara Sy do Operador Sobel

Assim, a medida de foco de Tenengrad é dada por:

$$TEN(I) = \sum_x \sum_y [S(x,y)]^2, \text{ para } S(x,y) > T$$

Equação 3 - Medida de foco de Tenengrad

Sendo,

$S(x,y)$ a magnitude do gradiente

T o limiar definido para a magnitude

Os estudos de Tenenbaum e Schlag *et al.*, que deram origem ao método Tenengrad, enfatizam o cuidado ao selecionar o limiar. Ambos os estudos definem métodos, porém a escolha do limiar envolve heurísticas. Assim, a escolha de não aplicar um limiar, ou seja, defini-lo como $T=0$ é uma alternativa (KROTKOV, 1987). Essa alternativa será aplicada a esse trabalho.

3 – Materiais e Métodos

Ao utilizar imagens obtidas em laboratório para analisar e classificar madeira, as amostras se encontram em uma condição ideal e possuem pouco ruído que possa interferir na classificação. Contudo, nem sempre é possível obter este tipo de imagem. As imagens utilizadas neste trabalho foram capturadas com câmeras digitais de baixo custo e em campo.

Os métodos de nitidez possuem relação com as bordas das imagens, por isso será utilizada a extração de características através da textura. O método a ser utilizado será o LBP Uniforme (LBPU), que possui a vantagem de manter as características de textura e utilizar um vetor de 59 posições, ao invés das 256 do LBP convencional, reduzindo o esforço computacional para o processo de classificação.

Segundo (YU *et al.*, 2009b), a cor, além de servir para identificação visual, também possui atributos estáveis, não sensíveis a rotação, a mudanças de escala e a outros tipos de deformações da imagem e ainda manter cálculos simples para extrair das amostras as características. O modelo de cor RGB será utilizado para a extração de características de cor.

A primeira etapa será separar as amostras nas proporções de treinamento, validação e testes. Após, as amostras serão divididas em janelas para cada um dos cenários propostos e também será utilizado um cenário sem essa divisão em janelas. Para cada cenário será feita a extração das características de textura e cor das amostras. Essas características serão submetidas a classificação de forma separada e combinada. Após a classificação os resultados também serão combinados de forma a possibilitar a avaliação de qual combinação possui o melhor resultado. Será feita a análise da taxa de acerto para todos os cenários propostos, considerando os resultados da classificação e nos cenários com divisão em janelas também será feita uma eleição com voto majoritário. A análise de nitidez será realizada nesse ponto, para classificar todas as amostras em alta e baixa nitidez. Será realizada novamente a análise da taxa de acerto, descartando as amostras de baixa nitidez, para todos os cenários propostos e também considerando o voto majoritário. Será feita uma

comparação entre os resultados com e sem a análise de nitidez de forma a verificar a contribuição na taxa de acerto.

3.1 – Divisão das amostras

O banco de dados descrito e utilizado em (PAULA FILHO *et al.*, 2010) possui 1119 imagens que estão divididas em 19 classes, conforme a Tabela 2.

Classe	Nome Popular	Nome Científico	Imagens
1	Roxinho	<i>Peltogyne sp</i>	137
2	Pinus	<i>Pinus sp</i>	47
3	Massaranduba	<i>Manilkara huberi</i>	55
4	Pau Cetim	<i>Aspidosperma sp</i>	74
5	Louro	<i>Laurus nobilis</i>	92
6	Cedro	<i>Cedrela fissilis</i>	32
7	Freijo	<i>Cordia goeldiana</i>	60
8	Grevilea	<i>Grevilea robusta</i>	49
9	Pau Amarelo	<i>Euxylophora paraensis</i>	48
10	Jatobá	<i>Hymenaea sp</i>	48
11	Cinamomo (Uva do Japão)	<i>Melia azedarach</i>	49
12	Ipe	<i>Tabebuia sp</i>	67
13	Bracatinga	<i>Mimosa scabrella</i>	45
14	Andiroba	<i>Carapa guianensis</i>	45
15	Amapá	<i>Brosimum paraensis</i>	57
16	Cumaru	<i>Dipteryx sp</i>	31
17	Cedrinho	<i>Erisma uncinatum</i>	85
18	Castanheira	<i>Bertolothia excelsa</i>	58
19	Araucária	<i>Araucaria angustifolia</i>	40

Tabela 2 - Banco de dados de imagens

A Figura 10 representa a base de dados de imagens que foram adquiridas através de uma câmera digital Sony DSC T20 e com a Tabela 2 é possível relacionar a representação das imagens com as espécies e a quantidade de imagens de cada classe. Cada amostra possui resolução de 3264x2448 *pixels*.




Figura 10 - Amostra da base de dados

As amostras de cada classe foram normalizadas pela menor quantidade de amostras, que corresponde a classe 16 com 31 amostras. A seleção das 31 amostras de cada classe a serem utilizadas foi aleatória e as amostras restantes de cada classe foram descartadas. Assim, foram utilizadas 589 amostras das 1119 disponíveis. As amostras foram divididas em treinamento, validação e testes, nas proporções de 11, 5 e 15 amostras respectivamente.

Foram elaborados cenários para a execução dos experimentos, dividindo cada uma das amostras em 12, 24, 36 e 48 janelas, de forma a aumentar o espaço amostral e possibilitar uma eleição através do voto majoritário para a classificação das amostras. A Figura 11 demonstra a divisão de uma amostra em janelas, onde cada janela terá um voto, de acordo com a classificação obtida, e a maior votação determinará a qual classe a amostra pertence. No caso de empate na votação, o voto é escolhido de forma aleatória entre as classes que obtiveram a maior votação.




Figura 11 - Divisão da amostra em janelas

Ainda, o cenário sem divisão das amostras em janelas também será considerado, para verificar se a divisão possibilita melhores resultados. Foi desenvolvido um aplicativo para realizar a divisão das janelas, nas dimensões de 816×816 pixels, para obter 12 janelas por amostra, 816×408 pixels para obter 24 janelas por amostra e 544×408 pixels para obter 36 janelas por amostra. A divisão em 48 janelas por amostra resultou em imagens de 408×408 pixels. É possível perceber que a divisão em janelas resultou em quatro cenários com imagens retangulares e um cenário com imagens quadradas. A Tabela 3 demonstra a quantidade de janelas após a divisão das amostras para cada um dos cenários propostos. A tabela 4 demonstra um resumo da quantidade de amostras e janelas, bem como a divisão das proporções para treinamento, validação e testes.

Cenário	Treinamento	Validação	Testes
Imagem inteira	209	95	285
Divisão em 12 janelas	2.508	1.140	3.420
Divisão em 24 janelas	5.016	2.280	6.840
Divisão em 36 janelas	7.524	3.420	10.260
Divisão em 48 janelas	10.032	4.560	13.680

Tabela 3 - Quantidade de janelas por cenário

Conforme a Tabela 4, as 31 amostras das 19 classes foram divididas em 15 (48,4%) para testes, 11 (36,5%) para treinamento e 5 (16,1%) para validação.

Item	Amostras
Classes	19
Amostras por classe	31
Amostras para teste	15
Amostras para treinamento	11
Amostras para validação	5

Tabela 4 - Divisão das amostras

3.2 - Extração e combinação de características

Foram utilizados dois conjuntos de características neste trabalho, sendo um conjunto relativo a cor e outro a textura. Utilizando características de cor, foi extraído o histograma normalizado cumulativo de cada canal do sistema de cores RGB. Foi empregado o método dos percentis de forma a reduzir a quantidade de elementos para a classificação. O histograma cumulativo é importante para o cálculo dos percentis, conforme descrito em (OLIVEIRA, 2008), assim sendo este o histograma utilizado. Os percentis foram divididos em um intervalo compreendido entre o 5º percentil e o 95º percentil. Dentro desse intervalo foram extraídos os valores de percentis com incremento de 10 posições, iniciando no 5º percentil e finalizando no 95º percentil. Esse método resultou em três vetores, sendo um de cada canal do modelo RGB, de 10 posições cada, totalizando 30 entradas para a classificação. Os vetores foram normalizados pela soma de todos os elementos e foram submetidos a classificação através de uma rede neural.

As características de textura foram extraídas utilizando o método LBP uniforme (LBPU). Inicialmente foram extraídas as características do LBP Uniforme, resultando em um vetor com 59 posições, que foi utilizado como entrada para classificação na rede neural.

Foram elaborados três tipos de combinação. Uma combinação, realizada antes da classificação, composta entre os dois métodos de textura e cor, resultando em um vetor combinado de 89 posições para a classificação, que é a soma dos dois vetores dos métodos. Essa classificação foi será referenciada como LBPU+RGB. As outras duas formas de combinação forma efetuadas após a classificação da rede neural, sendo a primeira o resultado da multiplicação do resultado da rede neural utilizada para a cor (RGB) e textura (LBPU) e a segunda da multiplicação das três redes neurais (RGB, LBPU e LBPU+RGB).

3.3 - Cálculo da nitidez

A análise de nitidez utilizará o método Tenengrad, conforme descrito do capítulo 2 deste trabalho. Foi desenvolvido um aplicativo utilizando a biblioteca OpenCV¹ versão 2.2 para o cálculo da medida de foco de Tenengrad. Como o índice de nitidez de uma imagem não é algo que pode ser facilmente reconhecido, como a cor, foram utilizadas amostras de imagens com diferentes níveis de nitidez, para verificar se os índices obtidos pelo aplicativo estavam de acordo com as imagens de entrada. Os testes do aplicativo utilizaram as figuras abaixo, onde gradativamente o foco da imagem era reduzido, de forma a diminuir a nitidez da imagem.



Figura 12 - Imagens para teste do algoritmo de nitidez

Fonte: <http://www.cs.cornell.edu/~erenrich/dof/>

As janelas que possuem um índice de nitidez baixo (pouco nítido) serão descartadas e serão desconsideradas na votação. É necessária uma definição de um limiar de nitidez para classificar as imagens em nítidas ou pouco nítidas. Assim, janelas de baixa nitidez são as que possuem índice de nitidez menor a média aritmética de todas as janelas da mesma amostra menos o desvio padrão referente as janelas da mesma amostra. Assim,

¹ Disponível em: <http://opencv.org>

somente as janelas que possuem índice de nitidez superior ou igual a média menos o desvio padrão serão consideradas imagens de alta nitidez.

Assim, a definição de imagens de alta nitidez é expressa na Equação 4 como:

$$TEN(I) \geq \bar{X} - \sigma$$

Equação 4 – Definição de alta nitidez

Sendo:

$TEN(I)$, o índice da janela obtido pelo método de Tenengrad,

$\bar{X}$ a média aritmética de todos os índices de Tenengrad das janelas uma mesma amostra e

σ o desvio padrão de todos os índices de Tenengrad das janelas de uma mesma amostra.

No caso da imagem inteira, considera-se todas as amostras como o conjunto a ser avaliado para se obter a média aritmética e o desvio padrão.

Por consequência, a definição de imagens de baixa nitidez, é definida na Equação 5 como:

$$TEN(I) < \bar{X} - \sigma$$

Equação 5 – Definição de baixa nitidez

Sendo os parâmetros os mesmos utilizados na

Equação 4.

Os resultados dessa classificação serão comparados com os resultados da classificação do tamanho de janela sem os descartes e também com as amostras originais, sem a divisão em janelas. Essa comparação irá determinar se a análise de nitidez contribui para melhorar a taxa de acerto, que é uma hipótese proposta nesse trabalho.

3.4 – Classificação através de rede neural

Para a classificação foram utilizadas redes neurais artificiais (RNA) do tipo *Multi Layer Perceptron* (MLP) através da ferramenta JavaNNS², que é um simulador de redes neurais. A avaliação da identificação de cada imagem consistirá em dividir cada uma em

² Disponível em: <http://www.ra.cs.uni-tuebingen.de/downloads/JavaNNS/>

partes menores, e extrair características de cada parte. Essa divisão será feita experimentalmente, de forma empírica. A análise de cada parte será submetida ao classificador e serão feitas 4 análises para obter o índice de acerto: taxa de acerto geral das janelas, taxa de acerto geral das janelas descartando as janelas de baixa nitidez, voto majoritário das janelas de uma mesma amostra e voto majoritário das janelas de uma mesma amostra descartando as janelas de baixa nitidez. O cenário sem divisão em janelas não terá voto majoritário, visto que não é possível pelo fato da amostra não possuir divisões.

A análise consiste em verificar qual método possui o maior índice de acerto e qual o impacto da análise de nitidez nos resultados. O algoritmo utilizado para o aprendizado da rede será o *Backpropagation* e a classificação será feita com todos os parâmetros padrão da ferramenta e o modo *shuffle* será utilizado para embaralhar as classes das amostras na classificação, visto que a extração de características que gera os dados para a entrada da rede o faz de forma ordenada por classe e isso pode influenciar a classificação. Foram desenvolvidos aplicativos para tratar a saída da rede, após aplicar as bases de testes, para obter os resultados para a análise.

3.5 - Resumo das técnicas

As técnicas podem ser divididas em dois grupos: antes da classificação e depois da classificação. Os métodos de extração de características realizados antes da classificação são os que serão submetidos à classificação através da rede neural, conforme a Tabela 5. Cada método possui o vetor de entrada da rede com os dados da extração das características das imagens a serem classificadas. Cada método de extração de característica possui uma quantidade de dados diferente para a entrada na rede neural. Os valores de cada vetor de entrada foram normalizados dividindo cada valor pela soma de todos os valores do vetor, de forma a padronizar a entrada dos dados com valores entre zero e um.

Método de extração de características	RGB	LBPU	RGB+LBPU
Algoritmo	RGB - 10 percentis por canal	LBP Uniforme	LBPU+RGB
Normalização do vetor	Soma dos elementos	Soma dos elementos	Soma dos elementos
RNA: entrada rede	30	59	89
RNA: algoritmo	Backpropagation	Backpropagation	Backpropagation

Tabela 5 – Resumo das técnicas antes da classificação

Dois métodos foram definidos para combinar os resultados após a classificação, de forma a trabalhar com a saída de cada rede neural, multiplicando seus resultados, alterando os dados dos vetores de saída de forma a verificar se há melhora na taxa de acerto. Essas combinações servem para ampliar o conjunto de dados para análise e verificar se essas transformações podem contribuir para o aumento da taxa de acerto.

As duas multiplicações utilizadas são mostradas na Tabela 6. As multiplicações são os valores dos vetores de saída das redes neurais multiplicados entre si, formando um novo conjunto de dados para análise. A primeira multiplicação se refere aos métodos RGB e LBPU, definida como $RGB \times LBPU$ e segunda multiplicação utiliza os métodos RGB, LBPU e $RGB+LBPU$, definida como $RGB \times LBPU \times (RGB+LBPU)$.

Método de extração de características	Combinação 1	Combinação 2
Vetores de saída combinados	RGB LBPU	RGB LBPU RGB+LBPU

Tabela 6 - Resumo das técnicas após a classificação

4 – Resultados experimentais

Para testar o método proposto, um conjunto de experimentos foi definido e executado. Inicialmente as amostras foram divididas nas devidas proporções para teste, treinamento e validação. Após isso, cada imagem foi dividida em diversas zonas, de acordo com os cenários propostos. Essas zonas serão referenciadas como janelas. Cada janela teve seu índice de nitidez calculado e as que obtiveram índice menor que a média menos o desvio padrão da amostra, serão definidas como janela de baixa nitidez. De forma análoga, as janelas de alta nitidez são definidas pelas janelas que possuem índice de nitidez maior que a média menos uma vez o desvio padrão. As janelas de baixa nitidez foram descartadas em uma segunda análise, de forma a avaliar se a nitidez possui impacto na classificação.

Para cada janela foram extraídas características de cor (RGB) e textura (LBPU) e essas características foram submetidas a uma classificação através de uma rede neural artificial juntamente com um vetor combinado dos dois métodos. Outro experimento realizado foi a combinação dos resultados dos três classificadores anteriores para analisar o impacto. Em todos os experimentos de divisão em janelas, foram analisadas quatro formas de avaliar o desempenho dos classificadores: taxa de acerto, taxa de acerto desconsiderando as imagens de baixa nitidez, taxa de acerto considerando voto majoritário de todas as janelas de cada amostra e taxa de acerto considerando voto majoritário das janelas de alta nitidez.

Foi desenvolvido um aplicativo, utilizando a biblioteca OpenCV, para dividir as imagens em zonas de dimensões arbitrárias, para possibilitar os experimentos desse trabalho. Conforme descrito na metodologia, foram definidos cinco cenários para a execução dos experimentos, que seus resultados serão expostos nesse capítulo.

Na seção 5.1 serão apresentados os resultados obtidos através da análise de nitidez, que serão utilizados em todos os cinco cenários propostos. A seção 5.2 irá expor os resultados obtidos com as imagens inteiras, sem divisão, para servir de parâmetro nos cenários seguintes, que consistem em dividir a amostras em diversas janelas e expostos nas seções 5.3 a 5.6.

4.1 – Análise de nitidez

Utilizando o método Tenengrad, descrito em no capítulo 2, todas as janelas foram submetidas a esse cálculo para obter o índice de nitidez, através de ferramenta desenvolvida nesse estudo para esse fim. As Janelas foram classificadas em alta nitidez, utilizando a definição da Equação 4 e em baixa nitidez, utilizando a definição da Equação 5.

A Figura 13 representa uma amostra da base de dados e a Figura 14 representa a mesma amostra, incluindo a divisão em janelas e incluindo os valores da análise de nitidez, nesse caso, arredondados apenas para obter melhor exibição.




Figura 13 – Amostra da base de dados



Figura 14 – Amostra da base de dados com divisão em janelas e índice de nitidez

A Tabela 7 reúne os dados de nitidez de cada janela. Com esses dados é possível calcular a média aritmética que resulta em 1322,42 e o desvio padrão que tem o valor de 807,39. Assim, segundo a

Equação 4, as imagens de alta nitidez serão aquelas que possuem o valor de nitidez acima de 515,03. Nesse caso somente a janela 1 seria considerada como baixa nitidez.

Valor nitidez	Janela
3062	6
2893	7
1253	10
1247	11
1240	8
1116	5
1082	3
1042	2
921	12
810	9
697	4
506	1

Tabela 7 – Valores de nitidez para a amostra

De acordo com a Tabela 8, o cenário de 12 janelas por amostra, 8,86% das janelas foram classificadas como baixa nitidez enquanto no cenário de 24 janelas, 8,45% das janelas foram classificadas como baixa nitidez. No cenário de 48 janelas e 7,23% das janelas foram removidas por baixa nitidez, sendo esse o menor percentual obtido. Ainda, percebe-se que na divisão de 36 janelas ocorreu o maior percentual de janelas removidas por baixa nitidez (15,97%), seguido pelo cenário de amostra inteira que obteve 12,28% das amostras removidas por baixa nitidez.

Cenário	Percentual de janelas com baixa nitidez
Amostra inteira	12,28%
12 janelas por amostra	8,86%
24 janelas por amostra	8,45%
36 janelas por amostra	15,97%
48 janelas por amostra	7,23 %

Tabela 8 – Percentual de janelas com baixa nitidez

4.2 – Uso da amostra inteira

A análise da amostra inteira servirá como parâmetro para todos os outros cenários, que serão apresentados nesse capítulo, de forma a comprovar se a divisão em janelas, através do voto majoritário e análise de nitidez parcial, ao invés da imagem como um todo, obtém melhores resultados. Pelo fato desse cenário não possuir divisão da mesma amostra em janelas, essa análise não possui possibilidade de voto.

A mostra os dados dos experimentos, no qual é possível perceber que o algoritmo RGB obteve as maiores taxas de acerto considerando todas as simulações, e que em todos os casos, a análise de nitidez melhorou os resultados. No caso do RGB, a exclusão das imagens de baixa nitidez melhorou em 1,28% a taxa de acerto, sendo esse o melhor índice para todas as simulações considerando a imagem sem divisão. Esse índice será utilizado como parâmetro para as simulações apresentadas nas seções seguintes.

Algoritmo Utilizado	RGB	LBPU	LBPU+RGB
Taxa de acerto	66,32%	44,21%	59,60%
Taxa de acerto desconsiderando imagens de baixa nitidez	67,60%	46,00%	61,05%

Tabela 9 – Taxa de acerto no cenário de amostra inteira

A combinação de classificadores não obteve melhores taxas na comparação, conforme a Tabela 10, sendo a melhor taxa obtida na combinação 2 considerando a análise de nitidez.

Combinação	Combinação 1 (RGBxLBPU)	Combinação 2 (RGBxLBPUx(LBPU+RGB))
Taxa de acerto	61,75%	63,51%
Taxa de acerto desconsiderando imagens de baixa nitidez	62,40%	63,60%

Tabela 10 - Taxa de acerto das combinações no cenário de amostra inteira

4.3 – Cenário com divisão em 12 janelas por amostra

A divisão em 12 janelas por amostra é o primeiro cenário que possibilita a análise da taxa de acerto através do voto majoritário. Em todas as análises o voto majoritário obteve igual ou melhor resultado do que a análise simples. A nitidez também contribuiu para o aumento da taxa de acerto, sendo o melhor método o LBPU+RGB considerando a nitidez e com voto majoritário que obteve 72,28% de taxa de acerto, sendo essa a maior em todo o cenário.

Algoritmo Utilizado	RGB	LBPU	LBPU+RGB
Taxa de acerto	56,99%	44,06%	58,98%
Taxa de acerto desconsiderando imagens de baixa nitidez	57,23%	44,63%	59,93%
Taxa de acerto com voto majoritário	70,53%	56,14%	71,93%
Taxa de acerto com voto majoritário desconsiderando imagens de baixa nitidez	70,53%	56,49%	72,28%

Tabela 11 - Taxa de acerto no cenário com divisão em 12 janelas por amostra

As duas combinações executadas após a classificação seguiram com a mesma característica da análise dos três algoritmos anteriores, com a combinação 1 (RGBxLBPU) obtendo a melhor taxa de acerto (71,58%), conforme a Tabela 12.

Combinação	Combinação 1 (RGBxLBPU)	Combinação 2 (RGBxLBPUx(LBPU+RGB))
Taxa de acerto	59,97%	58,13%

Taxa de acerto desconsiderando imagens de baixa nitidez	60,73%	58,71%
Taxa de acerto com voto majoritário	70,88%	66,67%
Taxa de acerto com voto majoritário desconsiderando imagens de baixa nitidez	71,58%	67,02%

Tabela 12 - Taxa de acerto das combinações no cenário com divisão em 12 janelas por amostra

4.4 – Cenário com divisão em 24 janelas por amostra

Na execução do cenário de 24 janelas por amostra, a combinação das características extraídas das janelas na classificação, pelo método do vetor combinado LBP uniforme e RGB, obteve melhores resultados em todos os experimentos realizados. O algoritmo LBP uniforme obteve as menores taxas de acerto em todos os experimentos. A análise de nitidez, nesse cenário, contribuiu para uma pequena redução da taxa de acerto em todos os experimentos. Observa-se que melhores taxas de acerto foram obtidas através da metodologia do voto majoritário, e a mais alta taxa de acerto, correspondente a 75,44% foi obtida pelo método do vetor combinado RGB e LBP uniforme considerando o voto majoritário das janelas da amostra. Em todos os casos a análise de nitidez causou uma redução nos índices de acerto, de acordo com a .

Algoritmo Utilizado	RGB	LBPU	LBPU+RGB
Taxa de acerto	57,63%	44,14%	62,11%
Taxa de acerto desconsiderando imagens de baixa nitidez	57,47%	43,90%	61,87%
Taxa de acerto com voto majoritário	73,33%	60,00%	75,44%
Taxa de acerto com voto majoritário desconsiderando imagens de baixa nitidez	72,98%	59,65%	74,74%

Tabela 13 - Taxa de acerto no cenário com divisão em 24 janelas por amostra

Na combinação dos resultados da classificação, a combinação 1 obteve melhores resultados em todos os experimentos em comparação com a combinação 2. Assim como nos experimentos sem combinação, a análise de nitidez não contribuiu para aumentar a taxa de acerto e as taxas de acerto mais altas foram as do método do voto majoritário. A taxa de acerto mais alta, inclusive superior aos métodos sem combinação posterior, foi na combinação 1 utilizando o voto majoritário, obtendo 76,49% de acerto, sendo essa a taxa mais alta para o cenário de 24 janelas por amostra.

Combinação	Combinação 1 (RGBxLBPU)	Combinação 2 (RGBxLBPUx(LBPU+RGB))
Taxa de acerto	61,68%	60,89%
Taxa de acerto desconsiderando imagens de baixa nitidez	61,47%	60,67%
Taxa de acerto com voto majoritário	76,49%	72,63%
Taxa de acerto com voto majoritário desconsiderando imagens de baixa nitidez	76,14%	71,93%

Tabela 14 - Taxa de acerto das combinações no cenário com divisão em 24 janelas por amostra

4.5 – Cenário com divisão em 36 janelas por amostra

O cenário de divisão em 36 janelas por amostra trouxe resultados mais relevantes com a análise de nitidez, ao contrário do que foi observado no cenário anterior. Ressalta-se que esse cenário obteve a maior taxa de imagens com baixa nitidez. O padrão observado no cenário de 12 janelas por amostra se repete nos três primeiros algoritmos desse cenário com a nitidez e o voto majoritário obtendo as maiores taxas de acerto, conforme a Tabela 15. O algoritmo LBPU+RGB obteve a melhor taxa de acerto com 78,25%.

Algoritmo Utilizado	RGB	LBPU	LBPU+RGB
Taxa de acerto	59,37%	45,18%	62,88%
Taxa de acerto desconsiderando imagens de baixa nitidez	61,28%	48,21%	63,50%
Taxa de acerto com voto majoritário	76,49%	62,11%	77,89%
Taxa de acerto com voto majoritário desconsiderando imagens de baixa nitidez	76,84%	62,46%	78,25%

Tabela 15 - Taxa de acerto no cenário com divisão em 36 janelas por amostra

Nesse cenário, também, a análise de nitidez aumentou a taxa de acerto em todas as análises, com exceção na combinação dos vetores utilizando o voto majoritário, onde a nitidez acabou por reduzir 0,35% a taxa de acerto em ambos os casos.

Combinação	Combinação 1 (RGBxLBPU)	Combinação 2 (RGBxLBPUx(LBPU+RGB))
Taxa de acerto	61,41%	60,98%
Taxa de acerto desconsiderando imagens de baixa nitidez	62,20%	61,76%

Taxa de acerto com voto majoritário	76,14%	73,68%
Taxa de acerto com voto majoritário desconsiderando imagens de baixa nitidez	75,79%	73,33%

Tabela 16 - Taxa de acerto das combinações no cenário com divisão em 36 janelas por amostra

4.6 – Cenário com divisão em 48 janelas por amostra

O último cenário proposto também mostrou o mesmo padrão observado em cenários anteriores, de o algoritmo LBPU+RGB obter as melhores taxas e a nitidez e o voto majoritário contribuindo para a melhora dos resultados. A Tabela 17 mostra os resultados.

Algoritmo Utilizado	RGB	LBPU	LBPU+RGB
Taxa de acerto	58,48%	45,02%	62,91%
Taxa de acerto desconsiderando imagens de baixa nitidez	58,91%	45,73%	63,40%
Taxa de acerto com voto majoritário	75,09%	64,21%	77,54%
Taxa de acerto com voto majoritário desconsiderando imagens de baixa nitidez	75,79%	64,21%	77,54%

Tabela 17 - Taxa de acerto no cenário com divisão em 48 janelas por amostra

As combinações mostraram resultados irregulares considerando a análise de nitidez. Na primeira combinação a análise de nitidez melhora pouco e iguala o índice enquanto a segunda demonstra uma redução nas taxas de acerto. A taxa de 78,25% obtida pela primeira combinação do voto majoritário desconsiderando imagens de baixa nitidez resulta na maior taxa do cenário.

Combinação	Combinação 1 (RGBxLBPU)	Combinação 2 (RGBxLBPUx(LBPU+RGB))
Taxa de acerto	63,49%	62,03%
Taxa de acerto desconsiderando imagens de baixa nitidez	64,38%	62,67%
Taxa de acerto com voto majoritário	77,89%	75,09%
Taxa de acerto com voto majoritário desconsiderando imagens de baixa nitidez	78,25%	74,04%

Tabela 18 - Taxa de acerto das combinações no cenário com divisão em 48 janelas por amostra

4.7 - Análise dos resultados

Após a execução dos cenários propostos e obtidos os resultados, foram elaborados alguns gráficos para analisar os dados e verificar tendências e pontos a serem observados.

A representa as taxas de acerto de todos os métodos propostos nos cinco cenários de divisões em janelas. Observa-se que o método LBPU obtém as menores taxas de acerto, próximo dos 45% enquanto os outros métodos variam entre as linhas de 55% e 70%. O método RGB obteve a melhor taxa de acerto no cenário da amostra inteira e taxas menores em todos os outros. Os três métodos combinados mostram menores variações de resultados.




Figura 15 – Taxa de acerto dos métodos

A análise de nitidez, conforme a Figura 16, melhora os resultados obtidos, com exceção do cenário de 24 janelas por amostra. Percebe-se um aumento da taxa de acerto no cenário de 36 janelas por amostra em todos os métodos. O método RGB e o método RGBxLBPUx(LBPU+RGB), assim como no gráfico anterior, obtém suas melhores taxas de acerto no cenário sem divisão em janelas.




Figura 16 - Taxa de acerto dos métodos desconsiderando imagens de baixa nitidez

A taxa de acerto com voto majoritário, demonstrada na Figura 17, trouxe a característica de curvas crescentes, nos métodos LBPU e RGBxLBPUx(LBPU+RGB), bem como taxas de acerto acima de 75%. Os cenários de 24 e 48 janelas por amostra concentraram os melhores resultados.




Figura 18 - Taxa de acerto dos métodos com voto majoritário

A análise de nitidez no voto majoritário trouxe o mesmo formato do gráfico do voto majoritário, conforme a e os resultados também foram similares.




Figura 19- Taxa de acerto dos métodos com voto majoritário desconsiderando imagens de baixa nitidez

A Figura 20 mostra a média aritmética de todos os métodos em cada cenário subtraído pela média aritmética dos mesmos métodos desconsiderando imagens de baixa nitidez. Essa subtração foi feita considerando a média aritmética dos cinco métodos, em cada cenário com todas as amostras, e a média aritmética dos cinco métodos, em cada cenário contendo somente as imagens de alta nitidez. Cada média foi subtraída uma da outra, de forma a avaliar se houve incremento na taxa de acerto, em média, ao utilizar somente imagens de alta nitidez.

+Assim, as seguintes subtrações foram consideradas:

- Imagem inteira
- Divisão em 12 janelas
- Divisão em 12 janelas com voto
- Divisão em 24 janelas
- Divisão em 24 janelas com voto
- Divisão em 36 janelas
- Divisão em 36 janelas com voto
- Divisão em 48 janelas

- Divisão em 48 janelas com voto

Esse gráfico serve como parâmetro para indicar qual foi o impacto da análise de nitidez em cada experimento. Percebe-se que em duas das nove médias subtraídas, a análise de nitidez contribuiu negativamente para os resultados, sendo ambos os casos da divisão em 24 janelas por amostra. A divisão em 36 janelas por amostra resultou no maior ganho de acerto, em média, sendo este também o cenário que houve a maior ocorrência de janelas de baixa nitidez.




Figura 20 – Impacto da análise de nitidez nos cenários propostos

5 – Conclusão e trabalhos futuros

A análise de nitidez possibilitou uma sensível melhora nos resultados. O impacto não foi maior devido ao método de análise de nitidez Tenengrad ter uma estreita relação com as bordas da imagem, o que em algumas janelas de determinadas amostras ocasionou a impossibilidade de obter um índice de nitidez relevante e que melhorasse a taxa de acerto de forma mais acentuada. Entretanto, o método de voto majoritário obteve bons resultados, sempre aumentando a taxa de acerto.

O método proposto se mostrou satisfatório para possibilitar a execução dos experimentos e pode ser utilizado em trabalhos futuros a fim de comparar resultados com outros tipos de dados e características.

O melhor resultado obtido foi a taxa de acerto de 78,25%, que ocorreu em dois casos. O primeiro, utilizando o método do vetor combinado RGB+LBPU, na divisão de 36 janelas por amostra, com voto majoritário e desconsiderando as amostras de baixa nitidez. Nesse caso, a análise de nitidez melhorou 0,35% os resultados. Os outro caso ocorreu no vetor combinado RGBxLBPU, na divisão de 48 janelas por amostra com voto majoritário também desconsiderando as amostras de baixa nitidez. A análise de nitidez em ambos os casos contribuiu para o acerto de uma amostra a mais, comparando com o voto majoritário sem a análise de nitidez, totalizando 223 acertos nas 285 amostras. Com esses resultados é possível concluir que a combinação das características de cor e textura também contribui para a melhora da taxa de acerto.

Como trabalho futuro, a combinação de outros métodos de extração de características, diferentes do LBP Uniforme para textura e do RGB para cor, como foi proposto neste trabalho. É possível também fazer novos experimentos alterando o limiar definido para a magnitude do método de tenengrad para obter resultados com o objetivo de comparar a utilização de limiares para as diferentes características das imagens. Ainda, é possível realizar outras de formas de combinação de características a melhorar os resultados obtidos. Outros métodos de cálculo de nitidez, também podem ser experimentados de forma a obter novos resultados, assim como a comparação dos mesmos pode ser efetuada e determinar qual método possui melhor resultado para a base de dados utilizada nesse estudo.

6 – Referências

(AHONEN, 2006) AHONEN, T., HADID, A., PIETIKAINEN, M. (2006) Face Description with Local Binary Patterns: Application to Face Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. V. 28, n. 12, p. 2037-2041.

(ANAICE, 2010) ANAICE, R., FACON, J. (2010) Avaliação de Nitidez em Imagens por Aprendizagem. *SIBGRAPI - Conference on Graphics, Patterns and Images*.

(BREMANANTH *et al.*, 2009) BREMANANTH R., NITHYA B., SAIPRIYA R. (2009) Wood Species Recognition Using GLCM and Correlation. *International Conference on Advances in Recent Technologies in Communication and Computing*. P. 615 – 619.

(CAVIEDES, 2002) CAVIEDES, J., GURBUZ, S. (2002) No-reference sharpness metric based on local edge kurtosis. *International Conference on Image Processing*. V. 3, p. 53-56.

(CHOUDHURY, 2011) CHOUDHURY, A., MEDIONI, G. (2011) Perceptually motivated automatic sharpness enhancement using hierarchy of non-local means. *IEEE International Conference on Computer Vision Workshops*. P. 730-737.

(DOSHI, 2012) DOSHI, N., SCHAEFER, G. (2012) A comparative analysis of local binary pattern texture classification. *Visual Communications and Image Processing*. P. 1 – 6.

(FERZLI, 2009) FERZLI, R., KARAM, L. (2009) A No-Reference Objective Image Sharpness Metric Based on the Notion of Just Noticeable Blur (JNB). *IEEE transactions on image processing*. V. 18, n. 4, p. 717-728.

(HUNT, 2004). HUNT, R. (2004) *The Reproduction of Colour*. John Wiley & Sons, 6^a Edição. 2004.

(KHALID *et al.*, 2008) KHALID, M., LEE, E. , YUSOF, R., NADARAJ, M. (2008) Design of an intelligent wood species recognition system. International Journal of Simulation Systems, Science & Technology. V. 9, n. 3, p. 9-19.

(KROTKOV, 1987) KROTKOV, E. (1987) Focusing. International Journal Comp. Vision. V. 1, p. 223-237.

(MÄENPÄÄ, 2004) MÄENPÄÄ, T., PIETIKÄINEN, M. (2004) Classification with color and texture: Jointly or separately?. Pattern Recognition. V. 37, n. 8, p. 1629-1640.

(MAHMOOD *et al.*, 2011) MAHMOOD, M., SHIM, S. CHOI, T. (2011) Depth and image focus enhancement for digital cameras IEEE 15th International Symposium on Consumer Electronics. P. 50-53.

(OJALA *et al.*, 1996) OJALA T., PIETIKINEN M., HARWOOD, D. (1996) A Comparative study of texture measures with classification based on featured distributions. Pattern Recognition. V. 29, n. 1, p. 51-59.

(OJALA *et al.*, 2002) OJALA T., PIETIKINEN M., MÄENPÄÄ, T. (2002) Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. IEEE Transactions on Pattern Analysis and Machine Intelligence. P. 971-987.

(OLIVEIRA *et al.*, 2008) OLIVEIRA, L. S., CAVALIN, P. R., BRITTO JR, A. S., KOERICH, A. L. (2008) Inspeção Automática de Defeitos em Madeiras de Pinus usando Visão Computacional. Revista de Informática Teórica e Aplicada. V. 15, n. 2, p. 203 – 218.

(PAULA FILHO *et al.*, 2010) PAULA FILHO, P. L., OLIVEIRA L. S., BRITTO JR, A. S., SABOURIN, R. (2010) Forest Species Recognition using Color-based Features. 20th International Conference on Pattern Recognition (ICPR). P. 4178 – 4181.

(PECH-PACHECO *et al.*, 2000) PECH-PACHECO J. L., CRISTÓBAL, G., CHAMORRO-MARTÍNEZ, J., FERNÁNDEZ-VALDIVIA, J. (2000) Diatom autofocusing in brightfield microscopy: a comparative study. International Conference on Pattern Recognition, V. 3, p. 314 – 317.

(PIETIKÄINEN *et al.*, 2011) PIETIKÄINEN, M, HADID A., ZHAO G., AHONEN, T. (2011) Computer Vision Using Local Binary Patterns. Computational Imaging and Vision. V. 40, p. 13-47

(RUSS, 2011) RUSS, J. (2011) The Image Processing Handbook. CRC Press. 6^a Edição. P. 43.

(TOU *et al.*, 2007) TOU, J. Y., LAU, P. Y., TAY, Y. H. (2007) Computer vision-based wood recognition system. Proceedings of International Workshop on Advanced Image Technology.

(TOU *et al.*, 2009) TOU, J. Y., TAY, Y. H., AND LAU, P. Y. (2009) A comparative study for texture classification techniques on wood species recognition problem. Fifth International Conference on Natural Computation.

(VU *et al.*, 2012) VU, C., PHAN, T ; CHANDLER, D. (2012) A Spectral and Spatial Measure of Local Perceived Sharpness in Natural Images. IEEE Transactions on Image Processing. V. 21, n. 3, p. 934-945.

(WANG, 1990) WANG, L., HE C. (1990) Texture classification using texture spectrum. Pattern Recognition, V. 23, p. 905-910.

(WEE, 2006) WEE, C., PARAMESRAN, R. (2006) Measure of image sharpness using eigenvalues. 9th International Conference on Signal Processing. P. 840-843.

(YU *et al.*, 2009a) YU, H., CAO, J., LUO, W., AND LIU, Y. (2009) Image retrieval of wood species by color, texture, and spatial information. International Conference on Information and Automation. P 1116 – 1119.

(YU *et al.*, 2009b) H.P. YU, W. LUO, J. CAO AND Y.X. LIU. (2009) Non-equal spacing division of HSV components for wood image retrieval. Proceeding of International Association of Wood Products Societies. P. 127–128.

(ZHU, 2010) ZHU, C., BICHOT, C., CHEN L. (2010) Multi-scale Color Local Binary Patterns for Visual Object Classes Recognition. International Conference on Pattern Recognition. P. 3065 – 3068.