

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE CIÊNCIAS AGRONÔMICAS
CAMPUS DE BOTUCATU**

**PROCESSAMENTO DE IMAGENS DIGITAIS PARA DETECÇÃO E
QUANTIFICAÇÃO DE DEFEITOS NA MADEIRA SERRADA DE CONÍFERAS DE
REFLORESTAMENTO DE USO NÃO ESTRUTURAL**

RICARDO RALL

Tese apresentada à Faculdade de Ciências Agronômicas da UNESP – Campus de Botucatu, para obtenção do título de Doutor em Agronomia (Programa de Pós-Graduação em Agronomia – Energia na Agricultura)

BOTUCATU - SP

Maio – 2010

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE CIÊNCIAS AGRONÔMICAS
CAMPUS DE BOTUCATU**

**PROCESSAMENTO DE IMAGENS DIGITAIS PARA DETECÇÃO E
QUANTIFICAÇÃO DE DEFEITOS NA MADEIRA SERRADA DE CONÍFERAS DE
REFLORESTAMENTO DE USO NÃO ESTRUTURAL**

RICARDO RALL

Orientador: Prof. Dr. Adriano Wagner Ballarin

Co-Orientador: Prof. Dr. Antônio César Germano Martins

Tese apresentada à Faculdade de Ciências Agronômicas da UNESP – Campus de Botucatu, para obtenção do título de Doutor em Agronomia (Programa de Pós-Graduação em Agronomia – Energia na Agricultura)

BOTUCATU - SP

Maio – 2010

FICHA CATALOGRÁFICA ELABORADA PELA SEÇÃO TÉCNICA DE AQUISIÇÃO E TRATAMENTO DA INFORMAÇÃO - SERVIÇO TÉCNICO DE BIBLIOTECA E DOCUMENTAÇÃO UNESP -FCA - FCA - LAGEADO - BOTUCATU (SP)

R163p Rall, Ricardo, 1968-
Processamento de imagens digitais para detecção e quantificação de defeitos na madeira serrada de coníferas de reflorestamento de uso não estrutural / Ricardo Rall. - Botucatu : S.d.,2010.
xiii, 123 f.: il., color., grafs., tabs.

Tese(Doutorado) -Universidade Estadual Paulista, Faculdade de Ciências Agrônômicas de Botucatu, 2010.
Orientador: Adriano Wagner Ballarin
Co-orientador: Antônio César Germano Martins
Inclui bibliografia.

1. Madeira serrada. 2. Processamento de imagens digitais. 3. Madeira. 4. *Pinus Taeda* L. I. Ballarin, Adriano Wagner. II. Martins, Antônio César Germano. III. Universidade Estadual Paulista "Júlio de Mesquita Filho"(Campus de Botucatu). Faculdade de Ciências Agrônômicas de Botucatu . III. Título.

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”

FACULDADE DE CIÊNCIAS AGRONÔMICAS

CAMPUS DE BOTUCATU

CERTIFICADO DE APROVAÇÃO

TÍTULO: “PROCESSAMENTO DE IMAGENS DIGITAIS PARA DETECÇÃO E QUANTIFICAÇÃO DE DEFEITOS NA MADEIRA SERRADA DE CONÍFERAS DE REFLORESTAMENTO DE USO NÃO ESTRUTURAL”

ALUNO: RICARDO RALL

ORIENTADOR: PROF. DR. ADRIANO WAGNER BALLARIN

Aprovado pela Comissão Examinadora



PROF. DR. ADRIANO WAGNER BALLARIN




PROF. DR. JOSÉ MARTINS DE OLIVEIRA JUNIOR



PROF. DR. ANTONIO ALVES DIAS



PROF. DR. JAYME LAPERUTA FILHO



PROF. DR. HERNANDO ALFONSO LARA PALMA

Data da Realização: 28 de maio de 2010.

Dedico este trabalho

A minha esposa Vera e aos meus filhos Ricardo, Lúgia e Luísa,
pelo amor, dedicação,
paciência e tanto carinho que me
ajudaram a alcançar mais esse grande objetivo.

Aos meus pais, por tudo que fizeram
e ensinaram: amor, carinho, educação e trabalho.

E às árvores que tombaram
e possibilitaram este trabalho.

AGRADECIMENTOS

Primeiramente gostaria de agradecer a grande Instituição Faculdade de Ciências Agronômicas de Botucatu – FCA pela honra e oportunidade que me concedeu, permitindo que eu cursasse o mestrado e o doutorado.

Ao professor Dr. Adriano Wagner Ballarin, por toda a paciência, amizade, apoio e orientação nos bons e maus momentos que passamos durante a elaboração deste trabalho, fica aqui minha eterna dívida e gratidão pela oportunidade.

Ao professor Dr. Antonio Cesar Germano Martins, pelos “primeiros passos” em PID, pelo conhecimento transmitido, amizade e apoio na co-orientação deste trabalho.

Aos professores Dr. Hernando Alfonso Lara Palma e Dr. José Martins de Oliveira Júnior por participarem de minha banca de qualificação e pelas pertinentes e valiosas sugestões e críticas dadas ao trabalho.

Ao eterno amigo e professor Dr. Ângelo Catâneo pelo apoio no difícil início do curso de mestrado.

A Gabriela pelo valioso auxílio no desenvolvimento do software.

Ao funcionário Ailton e aos alunos Elaine, Lucas e Humberto, do Laboratório de Ensaio de Materiais, do departamento de Engenharia Rural, pela colaboração na execução da parte técnica.

Aos funcionários Soler e Sílvio, da serraria da FCA, pelo apoio técnico na preparação dos corpos-de-prova.

Às bibliotecárias da FCA, pela revisão.

À Seção de Pós-Graduação da FCA, por todo o apoio.

4.5.2. Qualidade extra.....	43
4.5.2.1. A qualidade extra não admite peças com os seguintes defeitos.....	43
4.5.2.2. Outros defeitos são permitidos.....	44
4.5.3. Primeira Classe.....	45
4.5.4. Segunda Classe.....	47
4.5.5. Terceira classe.....	48
4.6. Fundamentos de imagem digital.....	50
4.6.1. Percepção visual.....	50
4.6.2. Tipos de sinais.....	52
4.6.3. Modelo de imagem.....	52
4.7. Imagem digital.....	53
4.7.1. Modelo de cor.....	53
4.7.2. Resolução espacial	54
4.7.3. Fotografia digital.....	55
4.7.4. Profundidade de cor.....	56
4.7.5. Arquivos digitais.....	57
4.7.6. Iluminância.....	57
4.8. Processamento de Imagens Digitais (PID).....	57
4.8.1. Áreas de aplicação.....	57
4.8.2. Etapas no processamento de imagens digitais.....	58
4.8.2.1. Aquisição de imagens	59
4.8.2.2. Armazenamento.....	60
4.8.2.3. Processamento.....	61
4.8.3. Realce de imagens.....	61
4.8.3.1. Brilho e Contraste.....	61
4.8.3.2. Histograma.....	62
4.8.3.3. Transformação da escala de cinza.....	64
4.8.4. Segmentação de imagens.....	66
4.8.4.1. Limiarização.....	67

4.8.4.2. Segmentação de regiões.....	72
4.8.4.3. Distância Euclidiana.....	74
4.8.4.4. Operações morfológicas de abertura e fechamento para eliminar artefatos.....	74
4.8.4.5. Operações lógicas.....	75
4.8.5. Reconhecimento e interpretação.....	76
4.9. Utilização de PID na classificação de diferentes materiais.....	78
5. MATERIAIS E MÉTODOS.....	81
5.1. Coleta e processamento mecânico das tábuas.....	82
5.2. Classificação manual das tábuas.....	86
5.3. Montagem do ambiente para aquisição das imagens.....	86
5.4. Aquisição das imagens das tábuas.....	87
5.5. Pré-processamento das imagens.....	91
5.6. Segmentação das imagens.....	91
5.6.1. Segmentação utilizando crescimento de regiões.....	89
5.6.2. Segmentação por limiarização (<i>thresholding</i>).....	92
5.6.3. Operação binária XOR.....	93
5.6.4. Operações morfológicas.....	93
5.7. Reconhecimento e interpretação das imagens.....	93
5.7.1 Medição de características morfológicas.....	93
5.7.1.1 Área do objeto.....	94
5.7.1.2 Comprimento da tábua.....	94
5.7.1.3 Largura média da tábua.....	95
5.7.1.4 Perímetro do objeto.....	95
5.7.1.5 Comprimento e largura do objeto.....	95
5.7.1.6 Largura máxima do objeto.....	96
5.7.1.7 Fator de forma do objeto.....	96
5.7.2 Medição de características cromáticas.....	96
5.7.2.1 Quantidade de pixels similares ao fundo.....	97
5.7.2.2 Médias, Medianas, Modas e Desvios-padrão.....	97

5.7.2.3 Percentil 5% inferior.....	97
5.7.3 Medição de características texturais.....	97
5.7.4 Medição de características estruturais.....	97
5.8. Classificação das tábuas.....	98
6. RESULTADOS.....	100
6.1. Iluminação utilizada no estúdio.....	100
6.2. Processamento mecânico das tábuas.....	100
6.3. Classificação manual das tábuas	100
6.4. Segmentação dos objetos.....	103
6.5. Classificação dos objetos segmentados.....	104
6.6. Imagens e resultados obtidos com o uso do software.....	106
6.6.1. Corte da imagem original.....	106
6.6.2. Segmentação utilizando crescimento de regiões.....	107
6.6.3. Segmentação da imagem do fundo.....	108
6.6.4 Segmentação dos nós.....	108
6.6.5. Segmentação da medula.....	109
6.6.6. Extração de características.....	110
6.7 Classificação das tábuas pelo software.....	111
7. CONCLUSÕES.....	113
8. REFERÊNCIAS.....	115
APÊNDICE	120

LISTA DE TABELAS

	Página
Tabela 1 – Dimensões padronizadas de madeira serrada.....	27
Tabela 2 - Classificação de madeira serrada de coníferas, provenientes de reflorestamento.....	49
Tabela 3 - Exemplos de cálculos de resolução de imagens.....	54
Tabela 4 - Exemplos de profundidade de cor.....	56
Tabela 5 - Medições de iluminância aferidas nos pontos distribuídos na tábua...	101
Tabela 6 - Classificação das tábuas, segundo ABNT 11.700.....	102
Tabela 7 - Relação de defeitos encontrados e suas ocorrências.....	103
Tabela 8 – Matriz de confusão do comparativo das classificações manuais e pelo software.....	111

LISTA DE FIGURAS

	Página
Figura 1 - Distribuição das plantações de <i>Pinus</i> , nos estados do Brasil, em 2008.....	23
Figura 2 - Evolução do consumo nacional dos produtos florestais oriundos de florestas plantadas de <i>Pinus</i> (1999-2008).....	24
Figura 3 - Efeito do nó na resistência da madeira.....	25
Figura 4 - Nó de borda.....	26
Figura 5a - Encurvamento: Exemplo de encurvamento.....	29
Figura 5b – Encurvamento: Medição do encurvamento.....	29
Figura 6a - Arqueamento.....	29
Figura 6b - Medição do arqueamento.....	29
Figura 7a - Encanoamento.....	30
Figura 7b – Medição do Encanoamento.....	30
Figura 8a - Esmoado.....	31
Figura 8b – Medição do Esmoado.....	31
Figura 9a - Exemplo de furos de insetos inativos.....	32
Figura 9b - Medição do furos de insetos inativos.....	32
Figura 10 - Medição de rachas.....	33
Figura 11a – Dimensão (diâmetro) de nó de face.....	34
Figura 11b – Dimensão (diâmetro) de nó de quina.....	34
Figura 12 – Exemplo de nó de gravata.....	34
Figura 13a – Exemplo de nós: nó firme.....	36
Figura 13b – Exemplo de nós: nó cariado.....	36
Figura 13c – Exemplo de nós: nó solto.....	36
Figura 13d – Exemplo de nós: nó vazado.....	36
Figura 14a - Exemplo de grupo e feixe de nós: Imagem de grupo de nós	37
Figura 14b - Exemplo de grupo e feixe de nós: Imagem de feixes.....	37
Figura 14c - Exemplo de grupo e feixe de nós: Esquema de medição e quantificação de nós.....	37
Figura 15a - Bolsa de resina.....	38

Figura 15b - Medição da bolsa de resina.....	38
Figura 16 - Exemplo de medula.....	38
Figura 17 - Medição da inclinação da grã.....	40
Figura 18 - Exemplo de mancha azul.....	41
Figura 19 - Exemplo de Fendilhado.....	41
Figura 20 - Exemplos de tábuas de classe Super.....	43
Figura 21 - Exemplos de tábuas de classe Extra.....	44
Figura 22 - Exemplos de tábuas de Primeira classe.....	46
Figura 23 - Exemplos de tábuas de Segunda classe.....	47
Figura 24 - Exemplos de tábuas de Terceira classe.....	48
Figura 25 - Esquema do olho humano.....	50
Figura 26a - Retângulos em fundo branco.....	54
Figura 26b - Matriz com a intensidade dos pixels.....	54
Figura 27a - Exemplos de resolução de imagens com 72 ppi.....	56
Figura 27b - Exemplos de resolução de imagens com 8 ppi.....	56
Figura 28 - Etapas de um processamento de imagens digitais.....	59
Figura 29 - Seção do espectro de energia eletromagnética.....	60
Figura 30a - Brilho: Imagem escura.....	62
Figura 30b - Brilho: Histograma.....	62
Figura 31a - Brilho: Imagem clara.....	63
Figura 31b - Brilho: Histograma.....	63
Figura 32a - Contraste: Imagem com baixo contraste.....	63
Figura 32b - Contraste: Histograma.....	63
Figura 33a - Contraste: Imagem com alto contraste.....	64
Figura 33b - Contraste: Histograma.....	64
Figura 34 - Equalização de histograma.....	66
Figura 35a - Imagem de madeira com nó.....	68
Figura 35b - Histograma da imagem de madeira com nó.....	68
Figura 36 - Imagem em tons de cinza com o respectivo histograma.....	70
Figura 37 - Imagem segmentada usando limiar $T = 133$	70

Figura 38 - – Imagem segmentada usando limiar $T = 164$	70
Figura 39 – Exemplo de crescimento de região.....	73
Figura 40 - Exemplo de operação morfológica.....	75
Figura 41 - Tora desdobrada.....	83
Figura 42 - Indicações de árvore e tora.....	84
Figura 43 - Desdobro das tábuas.....	84
Figura 44 - Conjunto das 84 numeradas seguindo o padrão estabelecido.....	85
Figura 45 - Planilha no Microsoft Excel para classificação de madeira de <i>Pinus</i>	86
Figura 46 - Vista posterior da estrutura em madeira para suporte da iluminação.....	87
Figura 47a - Deformação nas imagens: Imagem com deformação.....	88
Figura 47b - Deformação nas imagens: Imagem sem deformação.....	88
Figura 48 - Vista superior do arranjo geral adotado na aquisição das imagens.....	89
Figura 49 - Esquemas da aquisição das imagens. Arranjo geral.....	89
Figura 50 - Estúdio montado para a aquisição das imagens.....	90
Figura 51a - Avaliação da iluminância: vista geral das regiões de medição na tábua.....	91
Figura 51b - Avaliação da iluminância: posicionamento do luxímetro para medição.....	91
Figura 52 - Intermodes original.....	93
Figura 53 - Esquema de medição do comprimento da tábua.....	94
Figura 54 - Esquema de medição da largura média da tábua.....	95
Figura 55 - Caixa de limites, enquadrando um nó.....	97
Figura 56 - Fluxograma para a classificação das tábuas.....	99
Figura 57 - Tábua 72 – enquadramento na primeira classe motivada pela ocorrência de um único nó cariado.....	102
Figura 58 – Fluxograma da classificação dos defeitos.....	105
Figura 59a – Corte da imagem da tábua: imagem original.....	107
Figura 59b – Corte da imagem da tábua:imagem cortada no terço central.....	107
Figura 60 – Imagem resultante da segmentação por crescimento de regiões.....	108
Figura 61 – Segmentação para obtenção da imagem da tábuaua sem o fundo.....	108
Figura 62a – Segmentação para obtenção da imagem dos nós: imagem obtida por crescimento de região.....	108

Figura 62b – Segmentação para obtenção da imagem dos nós: imagem binária segmentada por limiarização dos nós.....	109
Figura 62c – Segmentação para obtenção da imagem dos nós: imagem original.....	109
Figura 62d – Segmentação para obtenção da imagem dos nós: imagem obtida pela operação XOR e pelas operações morfológicas.....	109
Figura 63a – Segmentação para obtenção da imagem da medula: imagem obtida por crescimento de região.....	110
Figura 63b – Segmentação para obtenção da imagem da medula: imagem binária segmentada por limiarização dos nós.....	110
Figura 63c – Segmentação para obtenção da imagem da medula: imagem original	110
Figura 63d – Segmentação para obtenção da imagem da medula: imagem obtida pela operação XOR e pelas operações morfológicas.....	110
Figura 64 – Planilha de resultados dos defeitos encontrados na tábua.....	111
Figura 65 – Planilha do resultado da classificação da tábua.....	111

1. RESUMO

No Brasil, a utilização de *Pinus* (de reflorestamentos) na indústria madeireira tem sido crescente nos últimos anos. Particularmente para a madeira serrada desse gênero, a produção nacional de madeira serrada de *Pinus* atingiu 9,46 milhões de m³ em 2008. O crescimento da produção no período de 1999 a 2008 foi de 40,6%. A produção de madeira em ciclos mais curtos tem tornado comum o decréscimo constante na oferta de árvores adultas com grandes diâmetros. Além do aspecto da juvenilidade, nota-se que a madeira hoje disponível para uso industrial e comercial apresenta uma incidência muito grande de nós e outros defeitos, que comprometem significativamente seu desempenho físico mecânico e sua qualidade. Diante dos números que apontam uma crescente demanda por produtos de madeira serrada de *Pinus*, é natural que a indústria busque formas mais eficientes de garantir a qualidade dos produtos por ela gerados; neste sentido a atividade de inspeção assume um papel importante no processo produtivo. De fato, a classificação de madeira serrada é afetada sensivelmente pela qualidade do trabalho desempenhado pelos graduadores humanos (trabalhadores das serrarias), pois essa é uma atividade estressante, exigindo grande atenção por longos períodos de tempo. O objetivo geral foi o desenvolvimento de técnicas de processamento de imagens digitais para detecção de defeitos na madeira serrada de coníferas. Os objetivos específicos foram, por meio da análise digital das imagens, analisar quais os parâmetros devem ser empregados para a detecção de defeitos na madeira serrada de coníferas, além de desenvolver um software de visão de máquina para a detecção de defeitos

na madeira serrada de coníferas. O material utilizado para o estudo foi a madeira extraída de seis árvores de *Pinus taeda* com 37 anos de idade, provenientes do Horto Florestal de Manduri – SP. As árvores foram desdobradas em tábuas, que originaram 84 tábuas, nas quais foram inicialmente analisados manualmente os nós, presença de medula e outros defeitos que comprometem sua qualidade, de acordo com os padrões estabelecidos pela NBR 12297 (ABNT, 1991). No processamento das imagens digitais adquiridas a partir dessas tábuas, o método adotado foi composto das seguintes etapas: montagem do ambiente para aquisição das imagens, aquisição das imagens das tábuas, pré-processamento das imagens, segmentação das imagens, reconhecimento e caracterização dos defeitos e classificação das tábuas. Os resultados obtidos revelaram que nenhuma das técnicas estudadas, quando aplicada isoladamente, foi satisfatória na detecção de nós, medula e bolsa de resina. Houve necessidade de se utilizarem combinações de técnicas para a segmentação de nós, medula e bolsa de resina e para o reconhecimento e caracterização dos nós cariados.

O software de processamento de imagens digitais, desenvolvido na linguagem Java, agilizou os processos de detecção, classificação dos defeitos (nós, medula e bolsa de resina) e das tábuas, com uma porcentagem de acerto de 90,5%, em um universo de 84 tábuas estudadas.

Palavras chave: madeira, *Pinus taeda* L., classificação, processamento de imagens digitais, madeira serrada.

DIGITAL IMAGE PROCESSING FOR DETECTION AND QUANTIFICATION OF DEFECTS IN CONIFEROUS WOOD REFORESTATION NON STRUCTURAL. Botucatu, 2010. 105p. Tese (Doutorado em Energia da Agricultura) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista.

Author: RICARDO RALL

Advisers: ADRIANO WAGNER BALLARIN and ANTONIO CESAR GERMANO MARTINS

2. SUMMARY

In Brazil, the use of *Pinus* (reforestation) in the timber industry has been growing in recent years. Estimates indicate that the volume of lumber produced in the country, estimated at about 22 million m³, more than 35% is made of pinewood. Timber production in shorter cycles has become common for the steady decline in the supply of mature trees with large diameters (ABRAF, 2009). In the aspect of juvenility, it is noted that the wood available today for industrial and commercial use has a very high number of knots and other defects that significantly impair their physical performance and mechanical quality. Given the numbers that indicate a growing demand for sawn timber products from pine, it is natural that the industry seek more efficient ways to ensure the quality of products generated by it, meaning that the inspection activity plays an important role in the production process. In fact, the classification of lumber is affected significantly by the quality of work performed by human graders (sawmill workers), because this is a stressful activity, requiring close attention for long periods of time. So, the aim of this study was to develop techniques of digital imaging to detect defects in lumber conifers. The specific objectives were, through the analysis of digital images, analyze which parameters should be taken to detect defects in lumber conifers, and develop a software for machine vision detection of defects in lumber conifers. The material used for the study was the wood from six trees of *Pinus taeda* with 37 years of age, from the forest nursery of Manduri - SP. The trees were split into planks, which led to 84 samples in which they were originally analyzed manually nodes, presence of bone marrow and

other conditions that compromise their quality in accordance with standards established by the NBR 12297 (ABNT, 1991). In the processing of digital images acquired from these boards, the method used was composed of the following steps: mounting environment for image acquisition, image acquisition of the samples, pre-image processing, image segmentation and classification. The results obtained revealed that none of the techniques used alone was satisfactory in detection of different defects in the planks. It was needed of techniques combination in order to obtain the node, bone and resin segmentation

The software created in Java language was efficient in detection and classification of the defects (node, bone and resin), in an assertive percentual of 90.5% from 84 boards.

Keywords: wood, *Pinus taeda* L., classification, quality, digital image processing, sawn wood, lumber.

3. INTRODUÇÃO

A utilização de *Pinus* de reflorestamento na indústria madeireira brasileira vem aumentando nos últimos anos. Particularmente para a madeira serrada desse gênero, a produção nacional de madeira serrada de *Pinus* atingiu 9,46 milhões de m³ em 2008. O crescimento da produção no período de 1999 a 2008 foi de 40,6%, porém devido à crise financeira mundial, em 2009 ocorreu um decréscimo de 2,1% (ABRAF, 2009).

Diante dos números que apontam uma crescente oferta e demanda por produtos de madeira serrada de *Pinus*, é natural que a indústria busque formas mais eficientes de garantir a qualidade dos produtos por ela gerados; neste sentido a atividade de inspeção assume um papel importante no processo produtivo.

Para todos os materiais e produtos a inspeção visual dos materiais ou produtos é necessária na indústria de transformação, para a caracterização e classificação da matéria-prima, para o controle do processo de fabricação e para a determinação da qualidade de produtos semi-acabados ou finais. As aplicações típicas de inspeção visual incluem peças fabricadas (dimensões e qualidade da superfície), a qualidade de impressão de etiquetas, o desgaste de ferramentas de usinagem, as placas de circuito impresso para colocação de componentes, a qualidade de juntas de solda e os produtos alimentícios como peixes, aves, carne bovina, biscoitos e café em grão, além do reconhecimento de defeitos de produtos têxteis, papel, aço e superfícies de madeira (KAUPPINEN, 1999).

Apesar do alto grau de automação nas linhas de produção nas

indústrias, as tarefas de inspeção de superfície dependem principalmente da visão humana (NEWMAN E JAIN, 1995). Desenvolver uma inspeção visual automática não é simples. A falta de métodos de caracterização de desempenho estabelecidos e a falta de estudos de caso complicam o desenvolvimento de sistemas de inspeção visual (DAVIES, 1997, HARALICK, 1992). Além disso, as tarefas de inspeção são, muitas vezes, mais complexas do que o esperado, pois muitos processos de inspeção visual requerem uma substancial habilidade e acuidade visual (NEWMAN e JAIN, 1995). Independentemente disto, a indústria transformadora está entusiasmada com a automação das tarefas de inspeção visual.

Os motivos gerais para a inspeção automatizada foram resumidos por Newman e Jain (1995) e Astrand (1996). A maioria dos benefícios da inspeção visual automatizada pode ser observada quando ela é comparada ao sistema de inspeção humana. Um sistema de inspeção automatizada pode operar de forma incansável e proporcionar uma qualidade consistente e com precisão, dos produtos inspecionados. Uma inspeção automatizada pode encontrar defeitos sutis demais para a detecção feita por um homem a olho nu e pode operar com velocidades mais altas do que o olho humano. Em um ambiente automatizado, as informações sobre cada um dos defeitos, o seu tipo, posição, tamanho e muitas outras podem ser analisadas, processadas e armazenadas ao mesmo tempo, o que não seria possível para um inspetor humano. Por outro lado, a flexibilidade dos inspetores humanos não deve ser subestimada. Por exemplo, a capacidade dos seres humanos para lidar com situações inesperadas é difícil de ser assimilada por um sistema de inspeção automatizado, pois um computador sem a programação antecipada não conseguirá sair de situações inusitadas, imprevistas.

Embora a inspeção automatizada esteja melhorando a produtividade, superando as desvantagens das inspeções manuais inconsistentes, proporcionando economia em despesas de trabalho, há também razões humanitárias para reflexão na utilização da inspeção manual. Existe o lado positivo, da geração de empregos, e o negativo, quando os trabalhadores são submetidos a tarefas de inspeção muitas vezes monótonas, entediantes e até mesmo perigosas.

No entanto, a inspeção visual automatizada nem sempre pode ser viável. Para ser viável, ela deve ser executada em tempo real e ser consistente, confiável, robusta e financeiramente factível (NEWMAN E JAIN, 1995). O conceito de tempo real é

dependente da aplicação e da resposta, que pode variar de milissegundos a minutos. Operação em tempo real de um sistema de inspeção é dependente de mecanismos que fornecem altas taxas de processamento de dados e utilizam complexos algoritmos. A viabilidade e robustez dos sistemas criados também são altamente dependentes de fatores como iluminação, objetos inesperados, poeiras, vibrações, mudança de velocidade do produto, etc. O custo de desenvolvimento e implementação também deve ser considerado. Normalmente, a inspeção automatizada é economicamente viável quando o pedido de inspeção é composto por grandes volumes, ou o grau de precisão é muito alto, ou está em um ambiente perigoso (KAUPPINEN, 1999). Atualmente, com os avanços de software e principalmente dos recursos de hardware nos sistemas computacionais, como processadores mais velozes, aliados ao decréscimo dos custos, a viabilidade de sistemas de inspeção automatizada ou de visão artificial está se tornando cada vez mais uma realidade.

Segundo Gomes et al. (2008), a produção de madeira serrada é afetada sensivelmente pela qualidade do trabalho desempenhado pelos graduadores humanos, pois essa é uma atividade estressante, exigindo grande atenção por longos períodos de tempo. Os graduadores são aqueles trabalhadores das serrarias que inspecionam as faces das tábuas para definir sua classificação. A qualidade de uma peça de madeira serrada é determinada por várias características de defeitos como: dimensões, posições, quantidade e tipos (LEE et al., 2003). Segundo a NBR 12297 (ABNT, 1991), os tipos de defeitos que devem ser observados para efeito de medição e quantificação são empenamentos, esmoados, furos de insetos inativos, rachas, bolsas de resina, medula, inclinação da grã, desbitolamento, madeira ardida, fendilhamento e nós, sendo este último o tipo de defeito de maior ocorrência (LEE et al., 2003). Também segundo Oliveira (2008), a maioria dos defeitos detectados em tábuas de *Pinus*, está relacionada à presença de nós.

Dessa forma, o estudo e desenvolvimento de técnicas e ferramentas de detecção de defeitos, encontrados na madeira serrada de coníferas, se tornam importantes na medida em que a evolução tecnológica, o aumento da demanda e a diminuição da oferta convergem para o mesmo objetivo: aproveitar da melhor forma possível a matéria-prima disponível, melhorando a eficiência em sua classificação e o desenvolvimento de mecanismos de visão artificial se mostram uma excelente alternativa.

3.1. Objetivos

O presente trabalho teve como objetivo geral desenvolver técnicas de processamento de imagens digitais para detecção dos principais defeitos na madeira serrada de coníferas de uso geral (não estrutural).

Teve, ainda, os seguintes objetivos específicos:

- Por meio da análise digital das imagens, eleger as melhores técnicas e revelar os parâmetros que devem ser empregados para a detecção de defeitos como nós, medula e bolsa de resina, na madeira serrada de coníferas.
- Desenvolver um software de visão de máquina para a detecção de defeitos na madeira serrada de coníferas.

4. REVISÃO DE LITERATURA

4.1. Origem e recortes históricos da introdução do *Pinus taeda* no Brasil

A introdução do gênero *Pinus* no Brasil ocorreu devido à necessidade da produção de madeira em plantações comerciais para abastecimento industrial, visando o processamento mecânico para a produção de madeira serrada ou laminada, confecção de painéis e produção de celulose e papel (KRONKA et al., 2005), aliada à quase extinção das matas de *Araucária angustifolia* (HERNANDEZ; SHIMABUKURO, 1978; SIMÕES et al., 1981).

O gênero *Pinus* apresenta, aproximadamente, 100 espécies e é originário de regiões temperadas e tropicais. Comercialmente, nos Estados Unidos, a espécie *P. taeda* pertence ao grupo denominado *Southern Pine*, que inclui várias espécies como *Longleaf Pine* (*P. palustris*), *Shortleaf Pine* (*P. echinata*), *Loblolly Pine* (*P. taeda*) e *Slash Pine* (*P. elliotti*) (USDA FOREST SERVICE, 2002).

O *Pinus taeda* é natural do sul e sudeste dos Estados Unidos, entre as latitudes 28° e 39°N e longitudes 75° a 97°W, onde a precipitação média anual pode variar entre de 900 a 2.200 mm, com distribuição constante durante o ano ou com até dois meses de seca. A temperatura média anual varia de 13°C a 19°C, com as médias mais quentes entre 20°C e 25°C e as mínimas, entre 4°C e 8°C (KRONKA et al., 2005), embora tenham sido registradas temperaturas extremas entre -23°C a 38°C (USDA FOREST SERVICE, 2002). É encontrada

em altitudes desde o nível do mar até 2.500 m, ocasionalmente até 4.500 m, com ampla variação do tipo de solo (KRONKA et al., 2005).

Com a evolução de sua produção, os principais usos da matéria prima estão sendo direcionados para o processamento industrial em serrarias, laminadoras e fábricas de chapas.

A Figura 1 apresenta a distribuição das plantações de *Pinus*, nos estados do Brasil, em 2008 (ABRAF, 2009)




Figura 1 - Distribuição das plantações de *Pinus*, em hectares plantados, nos estados do Brasil, em 2008.

Fonte: ABRAF (2009).

A madeira serrada de *Pinus* vem, nos últimos anos, apresentando um aumento constante no consumo nacional, conforme demonstra a Figura 2.




Figura 2 - Evolução do consumo nacional de madeira serrada oriunda de florestas plantadas de *Pinus* (1999-2008).

Fonte: ABRAF (2009).

Segundo Fonseca (2009), as perspectivas de crescimento no setor florestas plantadas são promissoras, até o ano de 2015, um montante superior a US\$ 30 bilhões serão investidos, sendo que o produto bruto da cadeia de transformação florestal no Brasil é da ordem de US\$ 50 bilhões anuais.

4.2. Lenho inicial e tardio em coníferas

A anatomia do lenho de coníferas é descrita e estudada detalhadamente por diversos pesquisadores, podendo-se citar, entre outros, Panshin e De Zeew (1980).

Uma característica comum das espécies de coníferas são os anéis de crescimento, que são formados por duas regiões que se alternam em cores claras e escuras, sendo essa variação, uma consequência das mudanças da formação da madeira, que é produzida pelas diferentes estações do ano. Em países tropicais e subtropicais, essa diferenciação está mais diretamente associada às variações na disponibilidade de água nas diferentes estações do ano. O anel de crescimento apresenta um lenho mais claro, chamado lenho inicial (*earlywood*) e um mais escuro, chamado de tardio (*latewood*). O lenho inicial é

composto basicamente por células com maior lúmen, paredes menos espessas e, conseqüentemente, madeira menos densa, enquanto o tardio apresenta células com paredes mais espessas e menor lume, resultando em madeira mais densa. Por conseqüência, a densidade do lenho inicial é menor do que a do tardio (BURGER; RICHTER, 1991).

Segundo Shimoyama e Barrichelo (1991), a densidade é uma das principais propriedades físicas da madeira, sendo a que melhor expressa a qualidade da madeira, pela fácil determinação e por apresentar correlação com outras características do produto.

4.3 Defeitos na madeira de coníferas

Os defeitos mais comumente observados nesse tipo de madeira são a presença de nós, inclinações das fibras, empenamentos, rachaduras e fendas (STANALKER e HARRIS, 1989).

Os nós, originados de galhos, interrompem a direção das fibras, causando desvios, com inclinações mais ou menos pronunciadas em torno deles. A sua influência sobre a resistência mecânica da peça varia, dependendo do seu tamanho e local. Quanto mais próximos às bordas, menor sua resistência à tração da peça. Segundo Haygreen e Bowyer (1996), em uma peça de 38 mm por 185 mm, um nó com 50 mm de diâmetro pode ter uma redução de resistência em até 24%, se o nó estiver em uma posição central (em relação à largura) na peça e de até 43%, quando os nós estão próximos às bordas.

A Figura 3 ilustra o enfraquecimento mecânico da madeira, causado pelo significativo desvio de fibras que o nó pode promover (STANALKER e HARRIS, 1989).




Figura 3 - Efeito do nó na resistência da madeira

Fonte: Stanalker e Harris, 1989

Os nós podem ser classificados de acordo com a área ocupada na seção transversal da peça, podendo estar localizados no centro ou no canto da face, ou no lado da peça. Um conjunto de nós é classificado a partir da observação de fibras inclinadas em torno de cada nó individualmente. Se forem identificadas fibras entre os nós que compõem o conjunto, ele é classificado como grupo de nós. Caso contrário, o conjunto é classificado como feixe de nós e o diâmetro desse conjunto de nós é a soma dos seus diâmetros (STANALKER e HARRIS, 1989).

Segundo Stanalker e Harris (1989), as forças aplicadas causam tensão de tração normal às fibras na região alterada pelo nó, solicitação para a qual a madeira tem baixa resistência. O enfraquecimento que ocorre pela presença do nó é significativo. O efeito dos nós é maior na resistência à tração do que na compressão. Além disso, nas peças tracionadas, os nós na linha central da face larga apresentam menor efeito que os nós presentes na borda da mesma face, pois esses causam excentricidade que pode induzir às tensões de flexão.

Na flexão, o efeito do nó depende da face (tracionada ou comprimida) em que ele se encontra. Segundo a American Society for Testing and Materials (ASTM) D245-93 (1998), quando a distância do centro do nó à borda é igual ou menor a $\frac{2}{3}$ do diâmetro do nó, ele é considerado nó de borda (Figura 4).




Figura 4 - Nó de borda

Fonte: ASTM (1998).

Ao redor do nó, a região de fibras inclinadas é menos rígida, paralelamente ao comprimento da peça em relação às zonas de fibras retas. Portanto, regiões de baixa rigidez são frequentemente associadas aos nós, sendo uma pequena parte do volume

total de uma peça. Os nós não têm muita influência na rigidez, que depende das características de todas as partes da peça, mas têm grande efeito na resistência, dependendo da proporção da seção transversal da peça que ocupam, da sua localização e da distribuição de tensões na peça (STANALKER e HARRIS,1989).

4.4 Medição e quantificação de defeitos na madeira serrada de coníferas (NBR 12297, 1991)

A madeira serrada pode ser definida como peças em forma de paralelepípedo, obtidas por meio do desdobro de toras em serras, que é um tipo de transformação primária da madeira. Dependendo do formato e das dimensões das peças, os serrados possuem diversas denominações, tais como: vigas, tábuas, pranchas, pontaletes, sarrafos, ripas e caibros (ABIMCI, 2004).

Segundo a NBR 12.498, as dimensões de madeira serrada de coníferas provenientes de reflorestamento devem ser padronizadas conforme Tabela 1.

Tabela 1 – Dimensões padronizadas de madeira serrada.

Tipo de peça	Espessura Nominal – e (mm)	Largura Nominal – l (mm)
Caibro	$50 \leq e \leq 100$	$50 \leq l \leq 100$
Pontalete	$e = 75$	$l = 75$
Prancha ou Pranchão	$e \geq 50$	$l > 150$
Pranchinha	$e = 38$	$l \geq 100$
Quadrado	$e = 25$	$l = 25$
Ripa	$e < 25$	$l < 100$
Sarrafo	$25 \leq e < 50$	$25 \leq l < 100$
Tábua	$25 \leq e < 38$	$l \geq 100$

Fonte: NBR 12.498 (1991).

A norma vigente que estabelece as regras gerais para medição e quantificação de defeitos em coníferas, provenientes de reflorestamento para uso geral (tábuas, caibros, vigas, etc.) é a NBR 12.297.

Devido à constatação de que essa norma não é adequada para a quantificação de defeitos em madeira serrada para uso estrutural (vigas, principalmente), onde é de extrema importância a posição do nó em relação às bordas da seção transversal (onde atuam as maiores tensões, nos casos de peças submetidas à flexão), está em fase de estudos, para posterior discussão pública e aprovação, um novo texto normativo, incorporado como Anexo G da NBR 7.190 (ABNT, 1997), que preconizará uma metodologia para a quantificação de defeitos em peças de madeira serrada de coníferas de uso estrutural. Este trabalho por sua vez, baseou-se nas normas NBR 12.297, NBR 11.700 e na detecção de defeitos como nós, medulas e bolsa de resina, tem como principal matéria prima a madeira serrada de coníferas para uso não estrutural.

A norma NBR 12.297 leva em consideração, para efeito de uma posterior classificação da madeira, os seguintes defeitos: empenamentos, esmoados, furos de insetos inativos, rachas, nós, bolsas de resina, presença de medula, inclinação da grã, desbitolamento e fendilhamento.

4.4.1. Empenamentos


É chamado de empenamento (*warp*) qualquer deformação na forma geométrica inicial das peças de madeira, devida à serragem, secagem ou ao armazenamento inadequados. Vários tipos de empenamentos são exemplificados a seguir.

Encurvamentos:


O encurvamento (*bow*) é um tipo de empenamento longitudinal da face, curvatura ao longo do comprimento da peça de madeira num plano perpendicular à face, conforme ilustra a Figura 5a.

O encurvamento é medido conforme mostra a Figura 5b e quantificado percentualmente em relação ao comprimento da peça, segundo a expressão:

$$\text{Encurvamento (\%)} = (x/L_1) \times 100 \quad (1)$$



(a)



(b)

x = maior flecha, em mm

L_1 = comprimento real da peça, em mm

Figura 5 – Encurvamento: a) Exemplo de encurvamento; b) Medição do encurvamento.


Fonte: ABPM (2001); ABNT (1991)

Arqueamento:


O arqueamento (*spring*) é o empenamento longitudinal das bordas; curvatura ao longo do comprimento da peça de madeira, num plano paralelo a face, conforme ilustra a Figura 6a.

É medido conforme a Figura 6b e quantificado percentualmente em relação ao comprimento da peça, por meio da expressão:

$$\text{Arqueamento (\%)} = (y/L_1) \times 100 \quad (2)$$



(a)



(b)

y = maior flecha, em mm

L_1 = comprimento real da peça, em mm

Figura 6 – a) Exemplo de arqueamento; b) Medição do arqueamento.


Fonte: ABPM (2001); ABNT (1991)

Encanoamento:


O encanoamento (*cup*) é o empenamento transversal da face; curvatura ao longo da largura de uma peça de madeira, conforme ilustra a Figura 7a.

É medido e quantificado em termos da diferença entre a espessura nominal e a espessura que se poderá obter após o aplainamento da peça de madeira encanoada, com fins à eliminação desse defeito, conforme mostrada na Figura 7b.

$$\text{Encanoamento} = e - e_a - 4 \text{ mm} \quad (3)$$



(a)



(b)

e_a = espessura aplainada, em mm
 e = espessura nominal, em mm

Figura 7 – Encanoamento. a) Exemplo de encanoamento; b) Medição do encanoamento.

Fonte: ABPM (2001); ABNT (1991)

4.4.2. Esmoado


Na língua inglesa é conhecido como *wane*, sendo a ausência de madeira, originada por qualquer motivo, na quina da peça de madeira; quina morta, conforme ilustra a Figura 8a.

A quantificação do esmoado é feita, percentualmente, em relação ao tamanho real de peça, tornando-se as definições dimensionais da Figura 8b e de acordo com as seguintes expressões.

$$\text{a) espessura percentual do esmoado} = (e_1 - e_2)/e_1 \times 100 \quad (4)$$

$$\text{b) largura percentual do esmoado} = (l_1 - l_2)/l_1 \times 100 \quad (5)$$

$$\text{c) comprimento percentual do esmoado} = L_1/L_2 \times 100 \quad (6)$$



- L_1 = comprimento real da peça
 L_2 = comprimento do esmoado
 l_1 = largura real da peça
 l_2 = diferença entre a largura real da peça e a maior largura do esmoado
 e_1 = espessura real da peça
 e_2 = diferença entre a espessura real da peça e a maior espessura do esmoado

Figura 8 – Esmoado. a) Exemplo de esmoado; b) Medição do esmoado.

Fonte: ABPM (2001); ABNT (1991)

No caso de a peça de madeira possuir dois ou mais esmoados na sua pior face, a quantificação será feita utilizando-se as mesmas fórmulas, além de também ser considerada:

- a maior espessura dos esmoados existentes;
- a maior largura dos esmoados existentes, quando ocorrerem em uma mesma quina; ou a somatória das larguras de dois esmoados, considerando a largura do maior esmoado existente em cada uma das duas quinas longitudinais da peça de madeira;
- o somatório dos comprimentos de todos os esmoados existentes.


4.4.3. Furos de insetos inativos

Nos furos de insetos inativos (*non-active insect hole*) observa-se perfuração na madeira causada por inseto desaparecidos, mortos ou sem indícios de suas atividades, conforme ilustra a Figura 9a.

Os furos de insetos inativos são medidos em função da área da peça de madeira por eles afetada, conforme a Figura 9b.



(a)



(b)

Área afetada pelos furos de insetos = $L_2 \times I_1$

L_1 = comprimento real da peça

L_2 = comprimento afetado pelos furos de insetos inativos

I_1 = largura real da peça

Figura 9 – a) Exemplo de furos de insetos inativos; b) Medição do furos de insetos inativos.

Fonte: ABPM (2001); ABNT (1991)

A quantificação da área afetada pelos furos de insetos inativos e dada percentualmente em relação à área da face inspecionada, conforme a fórmula abaixo:

$$\text{Furos de insetos (\%)} = (L_2 \times I_1) / (L_1 \times I_1) \times 100 \quad (7)$$

Um dos lados da área afetada por furos de insetos inativos deve corresponder, obrigatoriamente, a largura real da peça.

4.4.4. Rachas

Nas rachas (*split*) observa-se a separação dos constituintes da madeira paralelamente à grã.

As rachas são medidas conforme demonstrado na Figura 10, considerando como seus comprimentos as distâncias compreendidas entre linhas traçadas perpendicularmente às quinas e aos topos, e que as incluam.

A quantificação das rachas e feita considerando a soma de seus comprimentos, percentualmente, em relação ao comprimento real da peça, conforme a fórmula abaixo:

$$\text{Rachas (\%)} = (L_2 + L_3) / L_1 \times 100 \quad (8)$$




Figura 10 - Medição de rachas.

Fonte: ABNT (1991)

4.4.5. Nós

Os nós (*knot*) são partes de um galho ou ramo inserido no lenho durante o crescimento da árvore, constituído por um tecido lenhoso, cujos caracteres diferem daqueles da madeira que o circunda.

Segundo a NBR 12.297 (ABNT, 1991), para a classificação da peça são considerados apenas os nós que ocorrem na face (cada uma das duas maiores superfícies longitudinais de uma peça de madeira) e os nós de quina (inserção de uma face com uma borda ou inserção de duas faces) não sendo consideradas para efeito de medição as mudanças de inclinação da grã em torno desses nós.

Nós de face:

A dimensão de um nó que ocorre na face é dada pelo seu diâmetro em milímetros, o qual corresponde à distância máxima entre suas tangentes paralelas às quinas longitudinais da peça, conforme ilustrado na Figura 11a.

Nó de quina:

O nó de quina (*corner knot*) é aquele que aparece na borda e na face de uma peça e contém a interseção destas superfícies longitudinais.

O diâmetro de um nó de quina é dado pela distância máxima, entre a quina longitudinal, onde ocorre o nó, e a sua tangente, traçada na face e paralelamente a esta mesma quina (Figura 11b).




Figura 11 – a) Dimensão (diâmetro) de nó de face; b) Dimensão (diâmetro) de nó de quina.

Fonte: ABNT (1991)

Nó de gravata:

Segundo a NBR 12.551, é considerado um nó de gravata (*spike knot*) o conjunto de dois nós de formas alongadas e que convergem para o mesmo ponto na face da peça, conforme ilustra a Figura 12.




Figura 12 – Exemplo de nó de gravata.

Fonte: ABPM (2001)

O diâmetro de um nó de gravata é dado pela distância máxima obtida entre as tangentes que o incluem totalmente, traçadas paralelamente às quinas da peça de madeira.

Grupo de nós:

A NBR 12.551 prescreve que grupo de nós (*knot group*) é o conjunto de dois ou mais nós separados entre si por traqueídes desviadas da direção da grã, conforme ilustra Figura 13a.

O grupo de nós é medido, considerando-o como um único nó.

Feixe de nós:

Segundo a NBR 12.551 (ABNT, 2002), um feixe de nós (*knot cluster*) é um conjunto de dois ou mais nós agrupados, bem próximos entre si, formando uma só unidade, de maneira que não sejam identificadas visualmente as traqueídes entre os nós que o definem, conforme ilustra a Figura 13b.

O feixe de nós é medido de maneira análoga ao já apresentado para o grupo de nós.

Nó firme:

Segundo a NBR 12.551 (ABNT, 2002), um nó firme (*tight knot*) é do tipo que se mantêm firmemente retido na madeira seca, conforme ilustra a Figura 13a.

Nó cariado:

Segundo a NBR 12.551 (ABNT, 2002), um nó cariado (*unsound knot*) é o que se encontra parcialmente deteriorado por agente biológico ou mecânico, conforme ilustra a Figura 13b.

Nó solto:

Segundo a NBR 12.551 (ABNT, 2002), um nó solto (*loose knot*) é o que, normalmente, não se mantêm retido na madeira durante ou após a secagem, conforme ilustra a Figura 13c.

Nó vazado:

Segundo a NBR 12.551 (ABNT, 2002), um nó vazado (*knot hole*) é um orifício na peça de madeira provocado pela queda de um nó, conforme ilustra a Figura 13d.




Figura 13 – Exemplo de nós: a) nó firme; b) nó cariado; c) nó solto. d) nó vazado.

Fonte: ABPM (2001)

Quantificação de nós:

É dada percentualmente em relação à largura real por metro de comprimento da peça, considerando a soma de todos os seus diâmetros obtidos de acordo com os tipos de nós anteriormente citados e ainda conforme exemplificado na Figura 14c.

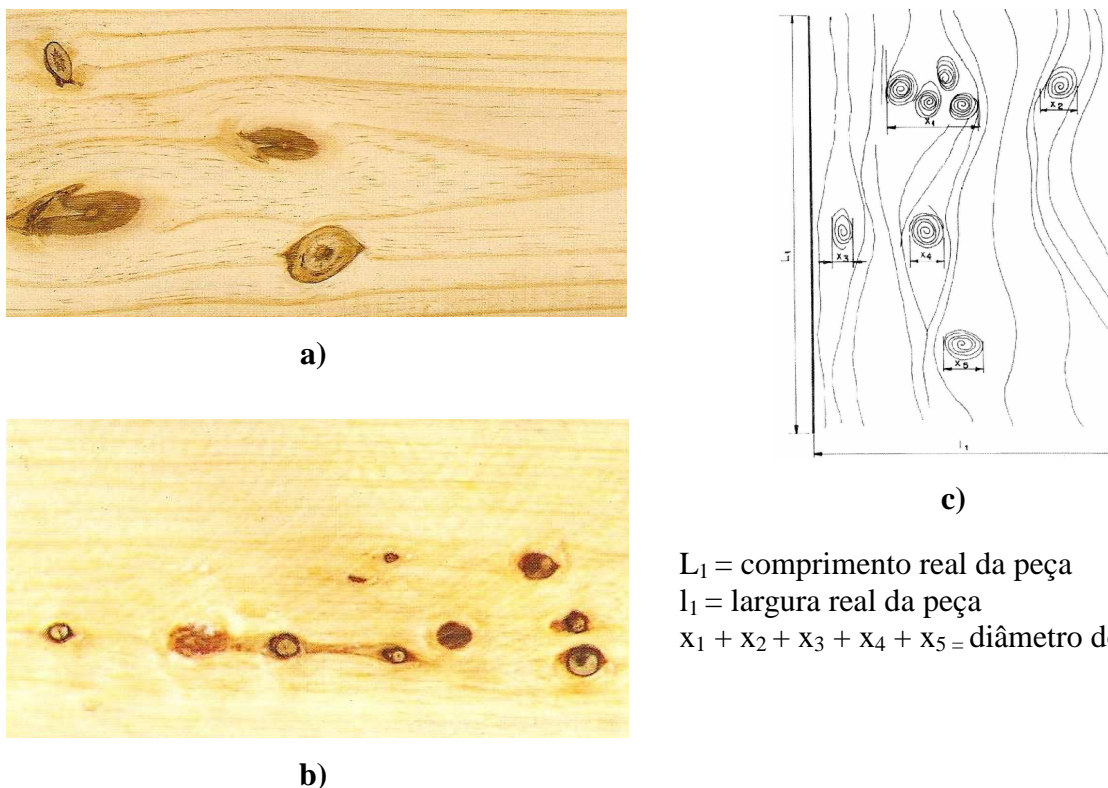


Figura 14 – Exemplo de grupo e feixe de nós: a) Imagem de grupo de nós; b) Imagem de feixes; c) Esquema de medição e quantificação de nós.

Fonte: ABPM (2001); ABNT (1991)

$$\text{Quantificação de nós (\%)} = ((x_1 + x_2 + x_3 + x_4 + x_5) / (L_1 \times l_1)) \times 100 \quad (9)$$

4.4.6. Bolsa de resina


Uma bolsa de resina (*resin pocket*) pode ser definida como uma cavidade mais ou menos alongada e bem delimitada que contém resina, conforme ilustra a Figura 15a.

A bolsa de resina é medida tomando-se sua largura e seu comprimento máximos, conforme a Figura 15a e ilustrada na Figura 15b. A quantificação da bolsa de resina é feita percentualmente em relação à largura e ao comprimento real da peça, conforme as expressões abaixo:


$$\text{largura da bolsa de resina (\%)} = I_2/I_1 \times 100 \quad (10)$$

$$\text{comprimento da bolsa de resina (\%)} = L_2/L_1 \times 100 \quad (11)$$

No caso da peça de madeira possuir duas ou mais bolsas de resina na sua pior face, a quantificação é feita considerando a somatória de suas larguras e de seus comprimentos, percentualmente em relação à largura e ao comprimento real da peça, respectivamente.



(a)



(b)

L_1 = comprimento real da peça

I_1 = largura real da peça

L_2 = comprimento da bolsa de resina

I_2 = largura da bolsa de resina

Figura 15 – Bolsa de resina. a) Exemplo de bolsa de resina; b) Medição da bolsa de resina.

Fonte: ABPM (2001); ABNT (1991)

4.4.7. Medição e quantificação da medula

A medula (*pith*) é a parte central do tronco constituída de tecidos menos resistentes que o restante do lenho, conforme ilustra a Figura 16.



Figura 16 – Exemplo de medula.

A medula é medida tomando-se sua largura e seu comprimento máximos relativos, obtidos das distâncias entre suas tangentes traçadas paralelamente e perpendicularmente às quinas, respectivamente.

A quantificação da medula é feita considerando diretamente o valor (em mm) de sua largura máxima e a correspondente porcentagem de seu comprimento máximo em relação ao comprimento real da peça de madeira, conforme apresentado na expressão:

$$C_m (\%) = L_2/L_1 \times 100 \quad (12)$$

Onde:

C_m = comprimento percentual da medula

L_2 = comprimento máximo da medula

L_1 = comprimento real da peça de madeira

No caso da medula apresentar-se descontinuada ao longo do seu comprimento, na face da peça de madeira, a quantificação é feita utilizando a mesma fórmula, mas considerando o somatório dos seus vários segmentos.

4.4.8. Medição e quantificação da inclinação da grã

A inclinação da grã é medida conforme apresentada na Figura 17, sem considerar desvios localizados.

Na tomada de medidas para a quantificação da inclinação da grã, a dimensão L_2 deve ser igual ou maior a duas vezes a largura real da peça (l_1),

A quantificação da inclinação da grã é dada pela seguinte fórmula:

$$I_g = l_2/L_2 \times 100 \quad (13)$$

Onde:

I_g = inclinação da grã, em %




Figura 17 - Medição da inclinação da grã.

Fonte: ABNT (1991)

4.4.9. Desbitolamento

O desbitolamento (*miscut lumber*) é a variação na espessura ou na largura de uma mesma peça, ocasionada por serragem malfeita.

O desbitolamento é medido e quantificado em termos da diferença entre as maiores largura e espessura encontradas na peça de madeira e as largura e espessura nominais respectivas.

4.4.10. Madeira ardida, mancha azul e mancha marrom

A madeira ardida (*incipient decay*) é um tipo especial de podridão incipiente. A mancha azul (*blue stain*), conforme ilustra a Figura 18, é uma coloração azulada produzida na madeira, devido à presença e ação de microrganismos específicos, ao contrário mancha marrom (*chemical brown stain*), onde ocorre o escurecimento da madeira, devido a degradação química do conteúdo celular, que ocorre alguns milímetros abaixo da superfície da peça, evidenciado após o aplainamento.

A madeira ardida, a mancha azul e a mancha marrom são quantitativas em termos percentuais de área afetada em relação à área total da peça.

A determinação da área afetada pode ser feita apenas visualmente, a não ser que, em caso de dúvida ou por exigência de interessados, seja requerida uma medição precisa.



Figura 18 – Exemplo de mancha azul

Fonte: ABPM (2001)

4.4.11. Fendilhado

Fendilhados (*seasoning check; superficial drying check*) são pequenas rachas superficiais (Figura 19), em geral alinhadas paralelamente à grã, que aparecem durante a secagem da madeira.

São considerados como fendilhados as pequenas rachas superficiais que apresentem largura menor que 1,0 mm e comprimento menor que 25,0 mm.



Figura 19 – Exemplo de Fendilhado.

Fonte: ABPM (2001)

4.5. Classificação da madeira serrada de coníferas para uso geral.

A partir dos defeitos identificados na madeira serrada de coníferas, a Associação Brasileira de Normas Técnicas sugere a classificação das peças de acordo com o preconizado na NBR 11.700 (1991) – Madeira Serrada de coníferas provenientes de reflorestamento para uso geral.

O método de classificação adotado nesta Norma é baseado no número e na importância dos defeitos encontrados numa peça. Cada classe de qualidade é definida pela descrição da pior peça de madeira que possa nela ser incluída, até aquelas que não possam ser incluídas na classe imediatamente superior.

Existem 5 classes de qualidade, denominadas de super, extra, de primeira, segunda e terceira classes e suas características estão apresentadas a seguir.

Segundo as condições gerais do código normativo, esporas (nós diminutos com até 3 mm de diâmetro), exsudação, inclinação da grã e grã entrecruzada são permitidas em todas as classes, sem restrições. Além disso, para todas as classes de qualidade, o encanoamento (empenamento transversal da face) é permitido desde que a espessura da peça, após o aplainamento, seja no máximo 4 mm inferior a espessura nominal correspondente.

Entre as condições comuns às quatro primeiras classes, não são permitidas peças que contenham furos de insetos ativos, galerias, podridão, torcimento e encurvamento complexo.

4.5.1. Qualidade super

4.5.1.1. A qualidade super (Figura 20) não admite peças que contenham qualquer um dos seguintes defeitos:

- a) nós soltos, vazados, cariados ou nós de gravata;
- b) furos de insetos inativos;
- c) rachas;
- d) madeira ardida;
- e) mancha azul ou marrom;
- f) bolsa de resina; ou
- g) medula.




Figura 20 – Exemplos de tábuas de classe Super.

Fonte: ABPM (2001)

4.5.1.2. A qualidade super admite peças com os seguintes defeitos:

- a) nós firmes, feixe de nós e grupo de nós com soma dos diâmetros não superior a 50% da largura, por metro de comprimento da peça;
- b) esmoado: desde que uma única quina, com espessura não superior a 15% da espessura da peça, largura não superior a 3% da largura da peça e comprimento acumulativo não superior a 20% do comprimento da peça;
- c) arqueamento e encurvamento não superiores a 0,5% do comprimento da peça;
- d) fendilhado: desde que não afete o aplainamento

4.5.2. Qualidade extra

4.5.2.1. A qualidade extra (Figura 21) não admite peças que contenham qualquer um dos seguintes defeitos:

- a) nós soltos, vazados, cariados ou nós de gravata.
- b) madeira ardida;




Figura 21 – Exemplos de tábuas de classe Extra.

Fonte: ABPM (2001)

4.5.2.2. Outros defeitos são permitidos, desde que observadas as restrições descritas a seguir:

- a) nós firmes, feixe de nós e grupo de nós com soma dos diâmetros não superior a 70% da largura, por metro de comprimento da peça;
- b) esmoado: desde que uma única quina, com espessura não superior a 15% da espessura da peça, largura não superior a 5% da largura da peça e comprimento acumulativo não superior a 20% do comprimento da peça;
- c) furos de insetos inativos, desde que a área por eles afetada não seja superior a 15% da área da peça;
- d) manchas azul e marrom, desde que a área afetada não seja superior a 10% da área da peça, para cada um desses defeitos;
- e) rachas: desde que o comprimento de cada uma não seja superior a 0,15m e que a soma de seus comprimentos não seja superior a 10% do comprimento da peça;
- f) bolsa de resina com largura acumulativa não superior a 5% da largura da peça e com comprimento acumulativo não superior a 25% do comprimento da peça;

- g) medula com largura não superior a 12 mm e comprimento acumulativo não superior a 15% do comprimento da peça;
- h) arqueamento e encurvamento não superiores a 1% do comprimento da peça.

Nota: Adicionalmente, não é permitida na qualidade extra, qualquer que contenha mais que seis tipos dos defeitos descritos acima, mesmo que estes ocorram dentro dos limites estabelecidos.

4.5.3. Primeira Classe

A primeira classe (Figura 22) de qualidade admite peças que contenham qualquer um dos seguintes defeitos:

- a) nós firmes, feixe de nós e grupo de nós com soma dos diâmetros não superior a 90% da largura, por metro de comprimento da peça;
- b) nós soltos, cariados e nós de gravata: com soma dos diâmetros não superior a 30% da largura, por metro de comprimento da peça;
- c) nós vazados com soma dos diâmetros não superior a 10% da largura, por metro de comprimento da peça;
- d) esmoado: desde que em uma única quina, com espessura não superior a 30% da espessura da peça, largura não superior a 10% da largura da peça e comprimento acumulativo não superior a 30% do comprimento da peça;
- e) furos de insetos inativos, desde que a área afetada não seja superior a 30% da área da peça;
- f) mancha azul, desde que a área afetada não seja superior a 25% da área da peça;
- g) rachas: desde que o comprimento de cada uma não seja superior a 0,20m e que a soma de seus comprimentos não seja superior a 20% do comprimento da peça;
- h) bolsa de resina com largura acumulativa não superior a 10% da largura da peça;
- i) madeira ardida, desde que a área afetada não seja superior a 10% da área da peça;
- j) arqueamento e encurvamento não superiores a 1,5% do comprimento da peça.




Figura 22 – Exemplos de tábuas de Primeira classe.

Fonte: ABPM (2001)

Nota: Adicionalmente não é permitida na primeira classe de qualidade qualquer peça que contenha mais que sete tipos dos defeitos descritos acima, mesmo que estes ocorram dentro dos limites estabelecidos.

4.5.4. Segunda Classe

A segunda classe (Figura 23) de qualidade admite peças que contenham qualquer um dos seguintes defeitos:

- a) nós soltos, cariados e nós de gravata com soma dos diâmetros não superior a 200% da largura, por metro de comprimento da peça;
- b) nós vazados com soma dos diâmetros não superior a 30% da largura, por metro de comprimento da peça;
- c) esmoado: sem restrições quanto ao número de quinas, com espessura não superior a 30% da espessura da peça, largura não superior a 20% da largura da peça e comprimento acumulativo não superior a 40% do comprimento da peça;
- d) furos de insetos inativos, com área afetada não superior a 50% da superfície;
- e) mancha azul, desde que a área afetada não seja superior a 50% da área da peça;
- f) rachas: desde que o comprimento de cada uma não seja superior a 0,50m e que a soma de seus comprimentos não seja superior a 50% do comprimento da peça;
- g) balsa de resina com largura acumulativa não superior a 15% da largura da peça;
- h) madeira ardida, desde que a área afetada não seja superior a 15% da área da peça;
- i) arqueamento e encurvamento: não superiores a 2% do comprimento da peça.




Figura 23 – Exemplos de tábuas de Segunda classe.

Fonte: ABPM (2001)

4.5.5. Terceira classe

A terceira classe (Figura 24) de qualidade não admite os defeitos que ultrapassam os limites das classes imediatamente superiores, exceto aqueles que inviabilizam a utilização da peça de madeira, como, por exemplo, a podridão em estado avançado de decomposição, furos de insetos ativos, etc.




Figura 24 – Exemplos de tábuas de Terceira classe.

Fonte: ABPM (2001)

A Tabela 2 apresenta as cinco classes segundo a norma e possibilita um melhor entendimento e visão geral sobre a classificação.

Tabela 2 - Classificação de madeira serrada de coníferas, provenientes de reflorestamento (ABNT, NBR 11.700, modificada)

Defeito		Característica	Classes de qualidade				Terceira
			Qualidade Super	Qualidade Extra	Primeira	Segunda	
nós	Firme, feixe de nós, grupos de nós	Soma dos diâmetros	$\leq 50\% l_{1/m}$	$\leq 70\% l_{1/m}$	$\leq 90\% l_{1/m}$	Sem restrições	Todos os defeitos que ultrapassem os limites da 2ª classe, exceto aqueles que inviabilizem a utilização da peça, tais como podridão avançada, furos dos insetos ativos, etc.
	Soltos, Cariados de gravata	Soma dos diâmetros	Não são permitidos	Não são permitidos	$\leq 30\% l_{1/m}$	$\leq 200\% l_{1/m}$	
	Vazados				$\leq 10\% l_{1/m}$	$\leq 30\% l_{1/m}$	
Bolsa de resinas		Soma das larguras	Não é permitida	$\leq 5\% l_1$	$\leq 10\% l_1$	$\leq 15\% l_1$	
		Soma comprimentos		$\leq 25\% L_1$	Sem restrições		
Medula		Larguras	Não é permitida	$\leq 12\text{ mm}$	Permitido sem restrições		
		Soma comprimentos		$\leq 15\% l_1$			
Rachas		Soma comprimentos	Não são permitidos	$\leq 10\% L_1$	$\leq 20\% L_1$	$\leq 50\% L_1$	
		Comprimen. individual		0,15 m	0,20 m	0,50 m	
Fendilhado		Profundidade	Não afere aplainamento		Permitido sem restrições		
Esmoadado		Espessura	$\leq 15\% e_1$	$\leq 15\% e_1$	$\leq 30\% e_1$	$\leq 30\% e_1$	
		Largura	$\leq 3\% l_1$	$\leq 5\% l_1$	$\leq 10\% l_1$	$\leq 20\% l_1$	
		Soma comprimentos	$\leq 20\% L_1$	$\leq 20\% L_1$	$\leq 30\% L_1$	$\leq 40\% L_1$	
		Número de quinas	1	1	1	2	
Mancha marron Mancha azul Madeira ardida Furos insetos inativos		Área afetada	Não são permitidos	$\leq 10\% A_1$	Permitido sem restrições		
				$\leq 10\% A_1$	$\leq 25\% A_1$	$\leq 50\% A_1$	
				Não é permitida	$\leq 10\% A_1$	$\leq 15\% A_1$	
				$\leq 15\% A_1$	$\leq 30\% A_1$	$\leq 50\% A_1$	
Galeria, furos insetos ativos, podridão, torc.		Presença	Não são permitidos				
Esporas, exsudação, grã entrecruzada e inclinação		Presença	Permitidos sem restrições				
todos		Quantidade	Sem restrições	≤ 6	≤ 7	Sem restrições	

Legendas e abreviações: L_1 : comprimento real da peça; l_1 : largura real da peça; e_1 : espessura real da peça; A_1 : área da face classificada da peça; comprimen.: comprimento; torc.: torcimento.

4.6. Fundamentos de imagem digital

4.6.1. Percepção visual

O olho humano fica no interior de uma cavidade óssea, denominada órbita, apresenta forma esférica irregular, com, aproximadamente, 20 mm de diâmetro e é protegido pelas pálpebras e cílios, conforme ilustra a Figura 25. É envolvido por três membranas. A mais externa é a esclerótica, que é uma camada resistente e opaca, protegendo as estruturas internas. A seguir, a coróide apresenta rede de vasos sanguíneos, responsáveis pela nutrição e oxigenação das estruturas internas. Essa camada é muito pigmentada, o que auxilia na redução da quantidade de luz que penetra pela pupila. A camada mais interna é a retina, que recobre a porção posterior do olho. Quando o olho focaliza um objeto, a luz desse objeto é transformada em imagem na retina, graças aos receptores presentes em sua superfície chamados de cones e bastonetes. Assim, a retina é responsável pela formação da imagem, projetada pelas estruturas da parte frontal do olho e transmite essas informações na forma de impulsos nervosos ao sistema nervoso central (GONZALES e WOODS, 2000; PEDRINI e SCHWARTZ, 2008).




Figura 25 – Esquema do olho humano
Fonte: Gonzales e Woods (2000).

Os cones estão localizados na mácula lútea, região central da retina, sensíveis a cores. Ao lado da mácula, está localizada a fóvea, onde as células estão afastadas, permitindo que a luz atinja plenamente os receptores e a acuidade visual é máxima. O número de cones pode atingir até 7 milhões e cada um é conectado a uma fibra nervosa, propiciando a visualização de pequenos detalhes pelo olho humano. Os cones são muito sensíveis a cores, devido a presença de uma substância fotossensível denominada fotopsina. Existem três tipos de cones, cada um responsável por diferentes comprimentos de onda, correspondentes ao azul (430 nm), verde-amarelada (575 nm) e vermelha (600 nm). A visão proporcionada pelos cones é chamada fotópica ou luz clara (GONZALES e WOODS, 2000; PEDRINI e SCHWARTZ, 2008).

Diferentemente dos cones, vários bastonetes são ligados a uma única fibra nervosa e estão amplamente distribuídos, reduzindo a percepção de detalhes, mas por outro lado, apresentam-se em número muito maior, entre 75 a 150 milhões. Essas estruturas não estão envolvidas na captação de cores, mas são responsáveis pelo campo de visão geral. Assim, um objeto visualizado na penumbra apresentará formas descoloridas, pois os cones não são estimulados sem a luz, ocorrendo somente o estímulo dos bastonetes, no processo chamado de visão escotópica ou luz escura (GONZALES e WOODS, 2000). Esse fenômeno ocorre devido a presença da rodopsina, que na presença de luz, altera a permeabilidade da membrana, com modificações do potencial elétrico no interior do bastonete. Com isso, ocorre a formação de sinapses com os neurônios da retina. Os sinais são, então, transmitidos para as células ganglionares, que dão origem às fibras no nervo óptico, que enviam esses sinais nervosos ao cérebro (GONZALES e WOODS, 2000; PEDRINI e SCHWARTZ, 2008).

A íris é formada pela divisão da coróide na extremidade anterior do globo ocular e pode contrair ou expandir, dependendo da quantidade de luz presente no ambiente. A frente da íris apresenta pigmentação variada, na sua parte posterior é sempre de pigmento negro. A abertura central da íris é denominada pupila, cujo diâmetro varia de 2 a 8 mm.

Atrás da íris está localizado o cristalino, que é uma lente gelatinosa, com a função de focalizar a luz, juntamente com a córnea. A distância focal do cristalino pode ser modificada por um anel de músculos denominados ciliares, que ajustam a visão, conforme a distância. Atrás do cristalino, está localizada a maior câmara do olho, preenchida por um

fluido viscoso, chamado humor vítreo. O humor aquoso se localiza entre a córnea e o cristalino e junto com o vítreo, é responsável pela estabilidade do volume e da pressão intra-ocular (GONZALES e WOODS, 2000; PEDRINI e SCHWARTZ, 2008).

Podem ser observadas muitas semelhanças e diferenças entre o olho humano e uma câmera fotográfica. A principal diferença entre o cristalino e uma lente óptica é a flexibilidade da primeira (GONZALES e WOODS, 2000).

Entre as semelhanças, o obturador da câmera e a pálpebra apresentam a mesma função. Assim como o diafragma de uma câmera, a íris do olho também controla a quantidade de luz que atravessa as lentes. Também podem ser comparadas as lentes da câmera com o cristalino e a córnea, que focalizam a luz, tornando as imagens nítidas, a serem formadas em uma superfície sensível. No caso do olho, essa superfície é a retina e nas câmeras fotográficas, são os filmes fotográficos (GONZALES e WOODS, 2000; PEDRINI e SCHWARTZ, 2008).

4.6.2. Tipos de sinais

Um sinal é a visualização de qualquer fenômeno expresso quantitativamente, podendo ser representado na forma de função ou de variáveis independentes e contendo informações das propriedades ou comportamento desse fenômeno (PEDRINI e SCHWARTZ, 2008).

Os sinais podem ser classificados como contínuos (quando seus estados podem ser definidos a qualquer tempo); sem interrupções (analógicos) ou como discretos (digitais, ocorrendo um conjunto de valores inteiros, com intervalos dependentes da natureza do sinal) (PEDRINI e SCHWARTZ, 2008).

4.6.3. Modelo de imagem

Um modelo matemático de uma imagem é necessário para a representação e manipulação dessa imagem no computador. Uma imagem é definida como uma intensidade luminosa, representada por $f(x,y)$, onde os valores da função nas coordenadas (x,y) fornecem a intensidade ou brilho da imagem naquele ponto (GONZALES e WOODS, 2000; PEDRINI e SCHWARTZ, 2008).

4.7. Imagem digital

Segundo Gonzales e Woods (2000), uma imagem digital é uma função $f(x,y)$ discretizada em coordenadas espaciais e brilho, sendo que, o valor da função em cada ponto da imagem, representa uma cor, e o conjunto desses pontos formam uma matriz onde os índices de linhas e de colunas identificam um ponto na imagem, chamado de elemento da figura ou da imagem, *pixel* ou *pels* (ambos abreviações de *pictures elements* – elementos de figura).

4.7.1. Modelo de cor

Segundo Trigo (2005), a localização do pixel na imagem é determinada pela sua posição em um sistema de coordenadas xy , e a cor associada ao pixel é dada por um número que representa a luminosidade de cada uma das cores primárias – vermelho, verde e azul (RGB, iniciais em inglês de *Red*, *Green* e *Blue*), formando um pixel.

O modelo RGB apresenta para cada cor os componentes espectrais primários de vermelho, verde e azul. Neste modelo as imagens consistem em três planos de imagens independentes, um para cada cor primária, que se combinam para produzir uma imagem de cores compostas (GONZALES e WOODS, 2000).

Conforme Gomes e Velho (1998), a luminância de uma cor com componentes R,G,B é dada pela equação:

$$I=0.299R+0.587G+0.114B \quad (14)$$

Esta equação é utilizada para decomposição das cores do sistema R,G,B e transformação de uma imagem colorida em uma imagem em tons de cinza.

A Figura 26a mostra dois retângulos (cinza e preto) em um fundo branco. A Figura 26b mostra a matriz que representa os pixels com suas intensidades luminosas. Nota-se que os pixels de intensidade 255 são brancos (luminosidade máxima), os de intensidade 0 (zero) são os pretos (nenhuma luminosidade) e os valores intermediários representam tons de cinza.




Figura 26 – a) Retângulos em fundo branco; b) Matriz com a intensidade dos pixels.

4.7.2. Resolução espacial

A resolução espacial é uma das mais importantes características de um sensor, determina o número de pixels que o formam e está intimamente ligada à qualidade da imagem produzida (TRIGO, 2005). Em uma imagem digital, a resolução espacial é o produto do número de pixels na horizontal pelo número de pixels na vertical.

A resolução espacial é a capacidade do sensor em resolver estruturas separadas por certa distância. Tem a ver com o número total de pixel usado para a obtenção da imagem. Usa-se para definir a resolução espacial, uma função denominada Função de Modulação (Modulation Transfer Function (MTF) (TRIGO, 2005).

Como o número de pixels presentes em um sensor é grande, pode-se adotar a unidade megapixels, termo em que o prefixo “mega” representa “milhões”, ou seja, milhões de pixels (TRIGO, 2005), conforme Tabela 3.


Tabela 3 - Exemplos de cálculos de resolução de imagens.

Pixels na vertical		Pixels na horizontal		Resolução
480	X	640	=	0,3 megapixel
768	X	1024	=	0,8 megapixel
1538	X	2048	=	3,1 megapixels
2048	X	2048	=	4,1 megapixels
1920	X	2560	=	4,9 megapixels
2048	X	3072	=	6,3 megapixels
4000	X	4000	=	16 megapixels
4080	X	5440	=	22 megapixels

Também é importante ressaltar que a resolução pode ser representada por um determinado número máximo de pixels por unidade de comprimento, neste caso

expressa pelo número de pixels por polegada, ou ppi ou dpi, do inglês *dot per inch* (TRIGO, 2005).

Na Figura 27a tem-se um exemplo de uma imagem com 72 ppi e na Figura 27b, uma imagem com 8 ppi. Pode ser observado que as imagens têm as mesmas dimensões, mas com diferentes resoluções, onde a resolução é diretamente proporcional a nitidez da imagem.



(a)

(b)

Figura 27 – Exemplos de resolução de imagens. a) Imagem com 72 ppi; b) Imagem com 8 ppi.

Ainda segundo Trigo (2005), uma imagem digital pode ser produzida basicamente de três formas. Por meio de um programa ou software, que forma no monitor imagens digitais representando figuras, letras e símbolos, por meio de um processo de escaneamento de um original, ou por uma câmera digital.

4.7.3. Fotografia digital

A fotografia digital é a atividade de se produzir imagens digitais a partir de câmeras fotográficas digitais. Ela é produzida quando um sensor eletrônico é colocado no plano focal (plano onde as imagens são formadas), nas câmeras convencionais esse é chamado de filme (TRIGO, 2005). Nas câmeras digitais atuais os sensores mais

utilizados são os *Charge-coupled device* (CCD). Basicamente esses sensores são responsáveis pela conversão do sinal luminoso em sinal elétrico, que é lido por conversor analógico-digital.

Segundo Trigo (2005), o conversor analógico-digital associa o número zero a uma voltagem mínima e o número 255 a uma voltagem máxima, que varia conforme o conversor utilizado. Desta forma, pode-se entender o que significam os valores associados às cores em RGB, com R=234, G=123 e B=052, onde quanto maior for o número associado a determinada cor, mais intensa ela será.

4.7.4. Profundidade de cor

É uma característica do sensor e do sistema eletrônico que acompanha o aparelho de aquisição de imagens. Ela determina o número de cores usadas na representação de cada pixel da imagem (GONZALES e WOODS, 2000).

A profundidade de cor é expressa em bits e a cada bit podem-se associar dois tons. Por exemplo, uma imagem preto (valor = 0) e branco (valor = 1) - sem tons de cinza - é representada por apenas 1 bit, uma imagem de 2 bits poderia assumir quatro valores na base numérica dois 00, 01, 10 e 11, onde respectivamente se tem preto, dois tons de cinza e o branco (TRIGO, 2005).

Ainda segundo Trigo (2005), o número de tons é determinado pela relação 2^n , onde n é a profundidade de cor, conforme demonstra a Tabela 4.

Tabela 4 - Exemplos de profundidade de cor

Profundidade (n)	Relação	Resultado
1 bit	→ 2^1	= 2 = 2 tons
2 bits	→ 2^2	= 2 x 2 = 4 tons
8 bits	→ 2^8	= 2 x 2 x 2 x 2 x 2 x 2 x 2 x 2 = 256 tons

A partir da profundidade de cor pode-se perceber que imagens em tons de cinza tem a profundidade de 8 bits, ou seja, 256 tons de cinza e as imagens coloridas, padrão RGB, tem a profundidade mínima de 24 bits, pois cada um dos três canais é representado por 8 bits (256 tons de vermelho, 256 tons de verde e 256 tons de azul). Combinando-se 256 x 256 x 256 temos 256^3 cores possíveis para cada pixel.

4.7.5. Arquivos digitais

Uma das operações mais importantes é o armazenamento das imagens captadas, para isso existem os arquivos digitais que é um formato de arquivo em código, um sistema de armazenamento de informações. Cada formato tem suas especificidades e aplicações mais apropriadas. Os formatos mais utilizados são *Tagged Image File Format* (TIFF), *Joint Photographic Experts Group* (JPEG), *Bitmap* (BMP) e *Graphics Interchange Format* (GIF) (TRIGO, 2005).

4.7.6. Iluminância

Segundo Pedrini e Schwartz (2008), iluminância corresponde à densidade do fluxo luminoso em um ponto da superfície, sendo medida em lúmen/m^2 ou lux (lx), candela, entre outras unidades

Iluminância é o conceito sobre a luz mais importante para os fotógrafos e pode ser medida por meio de um aparelho chamado luxímetro (TRIGO, 2005).

4.8. Processamento de Imagens Digitais (PID)

O processamento de imagens digitais envolve a captura, representação e transformação de imagens com o auxílio de um computador, permitindo identificar informações nas imagens, com a melhoria da qualidade visual, facilitando a interpretação humana e a automática, por meio de um computador e a extração de informações (CRANE, 1997; PEDRINI e SCHWARTZ, 2008). Problemas típicos que podem ser resolvidos utilizando técnicas de processamento de imagens são: o reconhecimento automático de um caractere específico, inspeção de produtos industrializados, reconhecimento militar, reconhecimento de impressões digitais, de imagens aéreas e de satélites para a previsão do tempo e monitoramento de plantio e de queimadas (GONZALES e WOODS, 2000).

4.8.1. Áreas de aplicação

Uma das primeiras aplicações do PID foi na melhoria das informações visuais para facilitar a interpretação humana, sendo utilizada em imagens digitalizadas para jornais, enviadas por cabos submarinos, na década de 20 (GONZALES e WOODS, 2000).

Devido ao avanço da tecnologia digital, as aplicações do PID têm sido cada vez maiores. Na área médica, tem auxiliado nos diagnósticos por imagem como tomografias computadorizadas, ressonância magnética, raios- X e ultra-sonografia, onde a análise e interpretação das imagens captadas facilitam a identificação de lesões, de tecido oncogênicos, máis formações intra-uterinas, etc., permitindo aos médicos maior precisão e rapidez no diagnóstico, tratamentos e procedimentos cirúrgicos (PEDRINI e SCHWARTZ, 2008).

Geógrafos têm utilizado imagens de raio X para estudar padrões de poluição em imagens aéreas ou de satélites (GONZALES e WOODS, 2000).

Muitas áreas de conhecimento vêm se beneficiando de imagens digitais, capturadas por microscópios ópticos ou eletrônicos, como contagem e identificação de células sanguíneas, análise de estruturas em cristalografia e o seqüenciamento e análise de DNA, na biologia. Na automação industrial, o PID auxilia na montagem e inspeção de produtos, visão robótica, controle de qualidade, verificação de falhas em circuitos impressos e em soldas e separação de peças por robôs em linha de montagem (PEDRINI e SCHWARTZ, 2008).

As imagens capturadas por satélites auxiliam no acompanhamento de áreas urbanas e rurais (erosão, desmatamento e queimadas) e previsão de fenômenos como terremotos, erupções vulcânicas, inundações e furacões. Na área militar, a análise de imagens digitais tem sido usada na identificação e rastreamento de alvos (PEDRINI e SCHWARTZ, 2008).

O PID também vem sendo muito utilizado na automação de muitas tarefas antes executadas por olhos humanos, como a identificação de impressões digitais e de faces, criação de retratos falados, o reconhecimento de assinaturas, de placas de veículos, controle de pedágios e estacionamentos, etc. (PEDRINI e SCHWARTZ, 2008).

4.8.2. Etapas no processamento de imagens digitais

O objetivo do processamento de imagens digitais é a geração de um resultado, a partir de um domínio do problema. A Figura 28 ilustra as etapas típicas envolvidas no processamento de imagens.

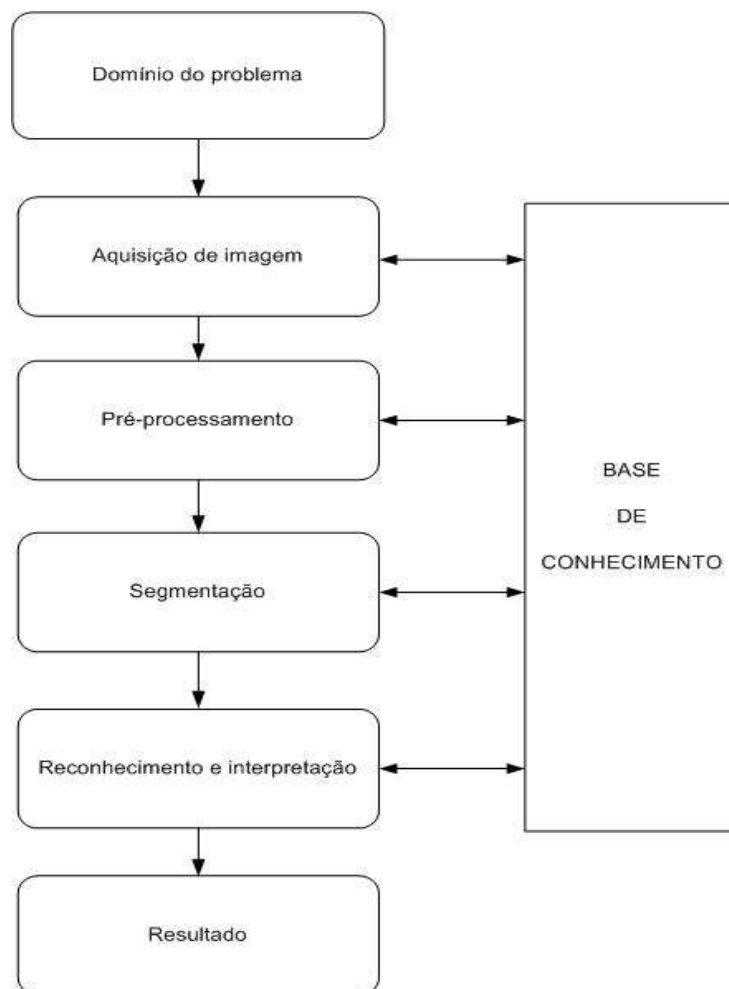


Figura 28 - Etapas de um processamento de imagens digitais.

4.8.2.1. Aquisição de imagens

Na aquisição de imagens são necessários dois elementos. Um dispositivo físico sensível a uma banda do espectro de energia eletromagnética e que produza um sinal elétrico de saída proporcional ao nível de energia da entrada. O segundo elemento é um conversor analógico-digital, usado para a conversão da saída elétrica de um dispositivo físico para a forma digital, tornando possível a interpretação pelo computador (GONZALES e WOODS, 2000).

Os tipos de energia eletromagnética mais usados são os raios X, ultravioleta, visível ou banda infravermelha, conforme mostra a Figura 29. Nos raios-X, a fonte de energia é direcionada para um objeto, atrás do qual é colocado um detector, sensível a

este tipo de onda eletromagnética. Assim, esse detector adquire a imagem do objeto, com diferentes graus de absorção de raios X. Entre os dispositivos que utilizam luz visível e infravermelha estão os microdensitômetros, analisadores de imagens, câmeras vidicon e matrizes de estado sólido fotossensíveis (GONZALES e WOODS, 2000).




Figura 29 – Seção do espectro de energia eletromagnética

Fonte: Gonzales e Woods (2000).

4.8.2.2. Armazenamento

O armazenamento de uma imagem ou dados é classificado em três tipos: o armazenamento por curto tempo, onde a imagem será usada somente durante o processamento; armazenamento *on line*, com acesso relativamente rápido e o armazenamento em arquivo, de uso menos frequente. O armazenamento é medido em *bytes* (oito bites) e seus múltiplos *Kbytes* (mil bytes), *Mbytes* (mega, um milhão de bytes), *Gbytes* (giga, um bilhão de bytes) e *Tbytes* (tera, um trilhão de bytes) (GONZALES e WOODS, 2000).

O armazenamento por curto período de tempo pode ser feito por meio do uso de memória do computador ou por mídias especializadas, que podem armazenar várias imagens e podem ser acessados rapidamente. Entretanto, a quantidade de armazenamento desses cartões é limitada pelo seu próprio tamanho físico e pela densidade dos circuitos de memórias.

O armazenamento *on line* é caracterizado pelo acesso frequente e ocorre por meio de discos magnéticos rígidos, que possuem centenas de megabytes (MB) ou gigabytes (GB).

4.8.2.3. Processamento

O PID geralmente é expresso em algoritmos, sendo necessária a presença de *softwares* especializados.

O processamento de determinada imagem é específico para aquele fim, onde técnicas que funcionam bem em uma área podem ser inadequadas em outra. Assim, a solução real de um problema específico pode exigir muita pesquisa e uma significativa equipe de desenvolvimento (GONZALES e WOODS, 2000).

4.8.3. Realce de imagens

O objetivo da utilização das técnicas de realce é a melhoria da qualidade da imagem, tornando-a mais adequada à aplicação específica. Essas técnicas são necessárias quando a imagem sofre qualquer tipo de degradação ou quando ocorre perda da qualidade pela presença de ruído, perda de contraste, presença de borrões, baixa qualidade do equipamento de aquisição da imagem pelo por iluminação inadequada (PEDRINI e SCHWARTZ, 2008).

Existem duas principais técnicas de realce. O *domínio espacial* refere-se ao plano da imagem com a manipulação direta dos pixels; enquanto o domínio de frequência baseia-se na modificação da imagem, no espaço das frequências após a mesma passar por uma transformação de Fourier (GONZALES e WOODS, 2000; PEDRINI e SCHWARTZ, 2008).

4.8.3.1. Brilho e Contraste

O brilho é associado à intensidade de luz emitida por uma fonte. A variação dessa intensidade pode ser percebida pelo olho humano, por meio de uma resposta logarítmica e não linear. Esse fato está baseado no princípio de que o sistema visual tende a super ou subestimar a intensidade próxima às transições entre regiões de intensidades distintas, pois mesmo em uma imagem de intensidade constante, pode ocorrer um padrão de brilho alterado. Esse fenômeno é chamado de *bandas de Mach*. No fenômeno de contraste simultâneo, onde o brilho aparente de uma região depende fortemente da intensidade do fundo, o anel de Benussi-Koffa é um bom exemplo, quando se observa que um anel com

intensidade uniforme aparenta ter brilho diferente quando uma reta separa os fundos da imagem (PEDRINI e SCHWARTZ, 2008).

O contraste é a medida da variação relativa da intensidade luminosa por unidade de área. Segundo a lei de Weber, a percepção do olho humano depende de variações de luz, ao invés da luminância absoluta (PEDRINI e SCHWARTZ, 2008).

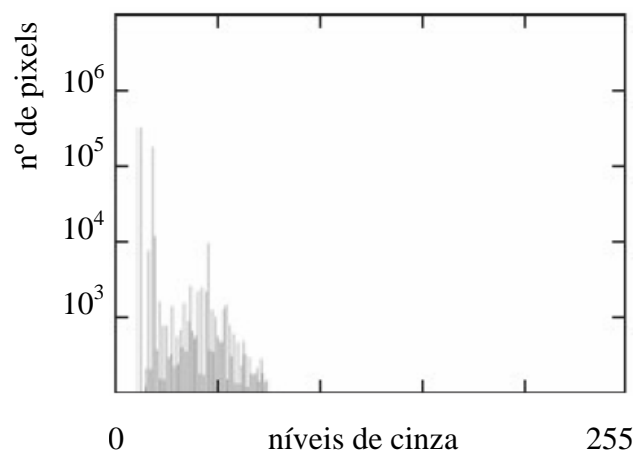
4.8.3.2. Histograma

O histograma pode ser definido pela distribuição dos níveis de cinza da imagem, representado por um gráfico, que indica o número de pixels para cada nível de cinza. Várias medidas estatísticas podem ser obtidas a partir de um histograma, como valores máximo e mínimo, valor médio, variância e o desvio padrão. Histogramas podem ser utilizados para a avaliação do contraste da imagem (PEDRINI e SCHWARTZ, 2008). Uma imagem colorida terá três histogramas, representando cada uma das cores do padrão RGB.

A Figura 30a apresenta uma imagem escura e a Figura 30b, seu respectivo histograma, onde se pode observar que os níveis de cinza estão concentrados próximos da cor preta, no início do histograma, nos valores mais próximos de 0.



(a)



(b)

Figura 30 – Brilho: (a) Imagem escura e (b) Histograma.

A Figura 31a apresenta uma imagem clara, com seu respectivo histograma (Figura 31b), onde os níveis de cinza estão concentrados próximos da cor branca, no final do histograma, com valores mais próximos de 255.




Figura 31 – Brilho: (a) Imagem clara e (b) Histograma.

Na Figura 32a tem-se uma imagem com baixo contraste e na Figura 32b seu respectivo histograma, onde os níveis de cinza encontram-se bastante concentrados.

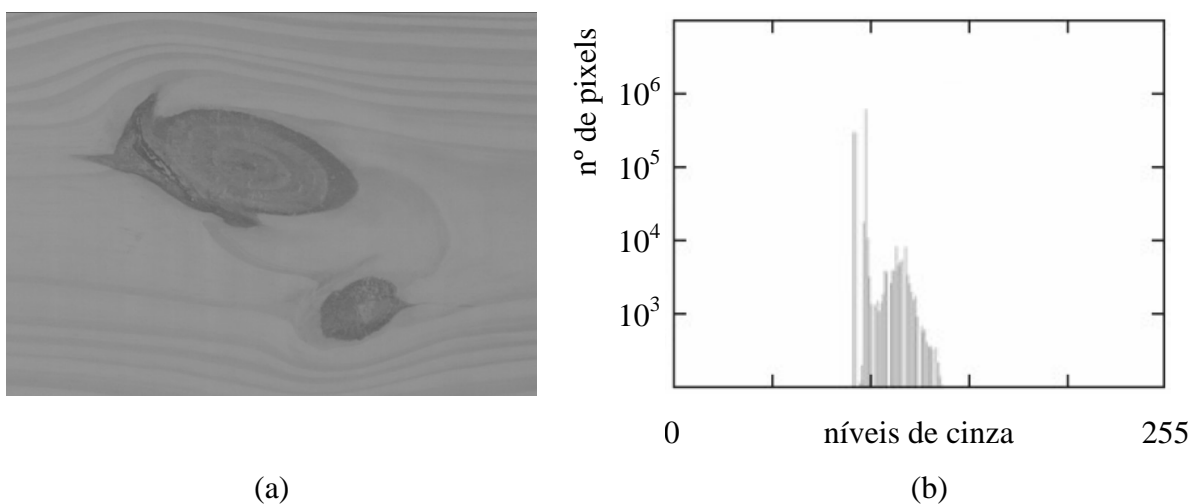


Figura 32 – Contraste: (a) Imagem com baixo contraste e (b) Histograma

A Figura 33a apresenta uma imagem com alto contraste e a Figura 33b seu respectivo histograma, onde os níveis de cinza se apresentam bem distribuídos ao longo da escala.




Figura 33 – Contraste: (a) Imagem com alto contraste e (b) Histograma.

4.8.3.3. Transformação da escala de cinza

Essas transformações visam melhorar a qualidade das imagens, facilitando a percepção das informações presentes na imagem. O intervalo de contraste é a diferença entre os valores de intensidade máximo e mínimo que $f(x,y)$ pode assumir. Se uma imagem não ocupa todo o intervalo de cinza, esse intervalo ainda pode ser ampliado por meio do mapeamento das variações de contraste dentro do intervalo dos níveis de cinza. Essa transformação ocorre pela função de mapeamento, onde cada valor de cinza da imagem original é mapeado para um novo valor (PEDRINI e SCHWARTZ, 2008).

A transformação da escala de cinza pode ser linear e não-linear, dependendo do tipo de função empregada.

A. Transformações lineares e não-lineares

Na transformação linear, ocorre o controle da escala de níveis de cinza da imagem resultante, com ajuste do brilho. Na transformação linear por partes ocorre a alteração da escala de cinza, com a existência de um conjunto de intervalos lineares. O realce é realizado de acordo com as intensidades dos pixels, situados em intervalos específicos.

Quando o histograma da imagem é muito irregular ou quando o objetivo é salientar um aspecto específico da imagem, a técnica por partes oferece melhores resultados que a única (PEDRINI e SCHWARTZ, 2008).

A transformação inversa produz o negativo de uma imagem, onde a intensidade da imagem de saída diminui conforme a da entrada aumenta (PEDRINI e SCHWARTZ, 2008).

Funções não lineares também podem ser usadas para realçar detalhes específicos na imagem e as principais funções desse tipo são baseadas na função logaritmo, raiz quadrada, exponencial e quadrado.

A transformação pelo logaritmo substitui cada pixel pelo seu logaritmo, levando a um maior realce nos pixels de baixa intensidade, que correspondem às regiões escuras. Semelhante a esta, a transformação pela raiz quadrada aumenta o contraste das regiões da imagem com baixa e médias intensidades. No tipo exponencial, cada valor de pixel é substituído pelo seu exponencial, levando a um realce maior nos pixels de alta intensidade, que correspondem às regiões claras. A transformação quadrado aumenta o contraste das regiões da imagem e alta intensidade (PEDRINI e SCHWARTZ, 2008).

B. Equalização de histograma

A equalização de histograma é o método no qual, por meio de uma transformação particular da escala de cinza, produz-se uma imagem com um histograma no formato adequado, onde ocorre a modificação do histograma da imagem original. A imagem transformada possui uma distribuição mais uniforme nos níveis de cinza (PEDRINI e SCHWARTZ, 2008), conforme ilustra a Figura 34, no gráfico em escala logarítmica.

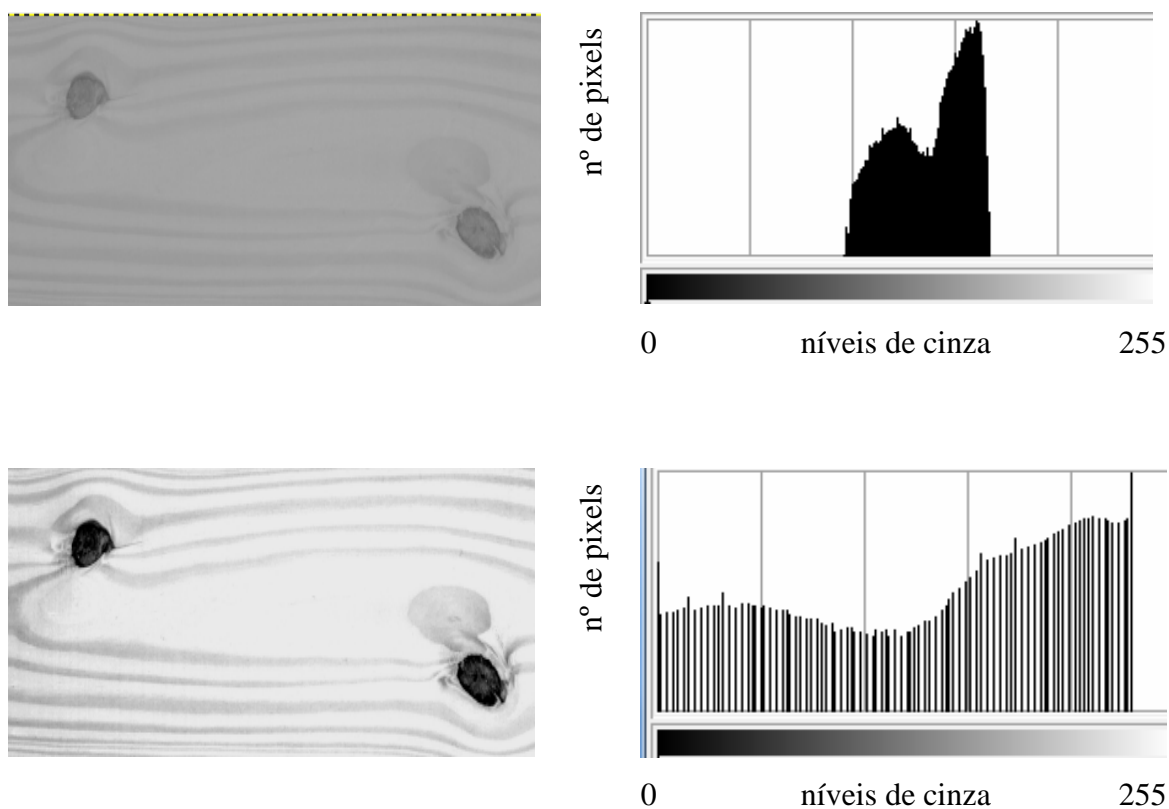


Figura 34 – Equalização de histograma

C. Especificação de histograma

A técnica de equalização pode alterar o histograma da imagem, de acordo com uma função de transformação padrão, de acordo com a função de distribuição acumulada dos níveis de cinza da imagem. Entretanto, existem situações onde a definição das formas específicas para o histograma da imagem é desejável e a especificação do histograma transforma uma imagem, de forma que seu histograma apresente uma distribuição particular (PEDRINI e SCHWARTZ, 2008).

4.8.4. Segmentação de imagens

A análise de imagens ocorre pela utilização de técnicas de extração das informações a partir de uma imagem. O primeiro passo para a análise é a segmentação, que divide a imagem em suas partes ou objetos constituintes, sendo que essa divisão deve parar quando os objetos de interesse estiverem isolados (GONZALES e WOODS, 2000).

Nos algoritmos de segmentação para imagens monocromáticas devem ser levadas em consideração as duas propriedades básicas de valores de níveis de cinza, a descontinuidade e a similaridade. Na descontinuidade, a imagem é dividida, segundo mudanças bruscas nos níveis de cinza e as suas principais áreas são a detecção de pontos isolados, de linhas e de bordas na imagem. Já a similaridade baseia-se na limiarização, crescimento de regiões e divisão e fusão de regiões (GONZALES e WOODS, 2000; PEDRINI e SCHWARTZ, 2008).

A segmentação, baseada em qualquer uma dessas duas propriedades, em relação aos níveis de cinza de seus *pixels*, é uma técnica que pode ser aplicada em imagens estáticas ou em movimento (GONZALES e WOODS, 2000).

Como já colocado, existem três tipos básicos de descontinuidade em uma imagem, os pontos, as linhas e as bordas. A detecção de pontos é obtida de maneira direta, pela medição das diferenças ponderadas entre o ponto central e seus vizinhos, onde o nível de cinza de um ponto isolado é completamente diferente do nível de cinza de seus vizinhos (GONZALES e WOODS, 2000).

A detecção de linhas é um pouco mais complexa e a detecção de bordas é a mais comumente utilizada para a detecção de descontinuidades significantes nos níveis de cinza, já que pontos e linhas finas isoladas não são ocorrências frequentes na maioria das aplicações práticas (GONZALES e WOODS, 2000).

Uma borda é a separação entre duas regiões com propriedades relativamente distintas de níveis de cinza. As regiões geralmente são suficientemente homogêneas, onde a transição entre essas regiões é determinada pela descontinuidade dos níveis de cinza. Se as regiões em questão não forem adequadamente homogêneas, a técnica de detecção de bordas não deve ser utilizada. Nessa técnica, numa imagem com uma faixa clara sobre um fundo escuro, o perfil da área de borda (transição do escuro para o claro) apresenta uma mudança gradual nos níveis de cinza ao invés de uma mudança abrupta (GONZALES e WOODS, 2000).

4.8.4.1. Limiarização

É a classificação dos *pixels* de uma imagem, pela especificação de um ou mais limiares, também chamado de “*threshold*”. A exatidão do valor do limiar é de extrema

importância para que o processo de segmentação apresente bons resultados (GONZALES e WOODS, 2000; PEDRINI e SCHWARTZ, 2008).

A limiarização global ocorre quando somente um valor de limiar é utilizado para segmentar toda a imagem, não sendo o processo mais adequado, pois as imagens, geralmente, apresentam variações nos níveis de cinza dos objetos e do fundo, devido à iluminação não uniforme e ruídos. No caso da imagem apresentar vários níveis de cinza, deve ser utilizada a limiarização local, onde os valores de limiar podem variar sobre a imagem (PEDRINI e SCHWARTZ, 2008).

A. Limiarização global

A melhor maneira de se obter um valor global de limiar pode ser obtido pela distribuição das intensidades dos *pixels* na imagem. Caso a imagem possua vários níveis de cinza, porém semelhantes, que diferem do nível de cinza do fundo, o histograma apresenta dois picos diferentes, um formado pelos *pixels* do objeto e o outro, pelos *pixels* do fundo, sendo, por essa razão, chamado de bimodal. O nível de cinza que melhor separa os dois picos é chamado de valor do limiar (PEDRINI e SCHWARTZ, 2008).

A Figura 35a mostra a imagem, em tons de cinza, de um detalhe de tábua com um nó e a Figura 35b apresenta o respectivo histograma com três picos, onde (a) contém os pixels mais escuros e próximo do valor 0, representado pelo nó, o pico (b) contém os pixels que representam os lenhos tardios e o restante da imagem, os pixels mais claros, está representada pelo pico (c), mais próximo do valor 255.




Figura 35 – a) Imagem de madeira com nó; b) Histograma da imagem de madeira com nó.

Foram relatadas algumas desvantagens na utilização do limiar global, pois nem sempre as intensidades dos objetos e do fundo são bem definidas, pela presença de baixo contraste ou de ruído. Além disso, podem existir vários pontos de mínimo ou máximo locais na mesma imagem.

Segundo Manson et al. (1975), o histograma pode ser modificado de acordo com a função do valor do contraste local, ponderado pelo inverso de seus valores de gradiente. As regiões de pixels com valores de gradientes baixos são mais influenciadas do que as de gradientes mais altos e assim, os picos do histograma causados por essas regiões podem ser removidos, a fim de facilitar a determinação do limiar.

Uma técnica semelhante, descrita por Wezka et al (1974) pondera as intensidades dos pixels com valores do gradiente para escolher o limiar no pico do histograma, correspondendo à transição entre as regiões. Uma vantagem é a necessidade da detecção de um ponto máximo, mais facilmente obtido do que a detecção de vales entre dois picos. O método Laplaciano resulta em valores altos para as transições das regiões da borda, utilizando um operador de diferenciação de segunda ordem (PEDRINI e SCHWARTZ, 2008).

Se alguma propriedade da imagem segmentada já for conhecida, a seleção do limiar pode ser simplificada, pois o valor do limiar é escolhido a fim de que essa propriedade seja satisfeita. Caso a porcentagem “p” de pixels do objeto seja conhecida, essa informação pode ser utilizada na escolha do limiar “T”, tal que o valor “p” da área da imagem apresente níveis de cinza menores que “T” e o restante dos níveis, menores que essa grandeza (PEDRINI e SCHWARTZ, 2008). Em 1962, Doyle propôs um método de seleção do valor de limiar, conhecendo-se a área coberta por caracteres de um texto em um fundo branco. No entanto, na prática, esse conhecimento prévio é raro.

A Figura 36 apresenta uma imagem em tons de cinza e o seu histograma.

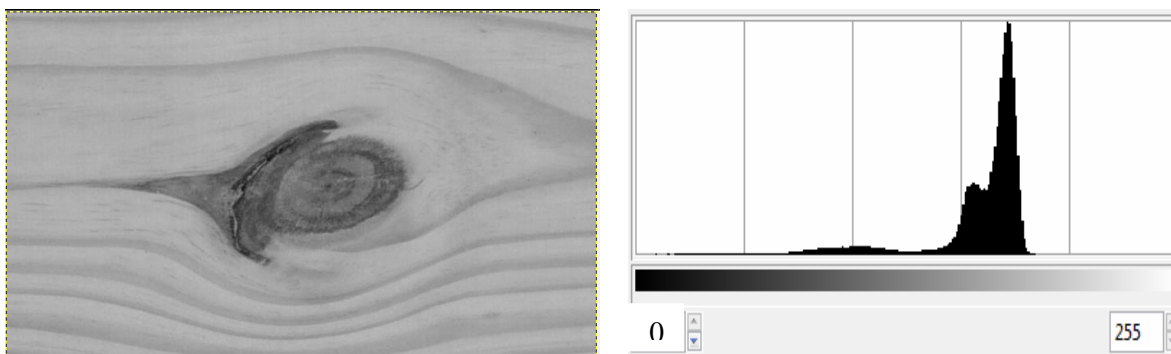


Figura 36 – Imagem em tons de cinza com o respectivo histograma.

As Figuras 37 e 38 apresentam a binarização e a segmentação da imagem anterior, em escala de cinza, utilizando-se limiar com valores de $T=133$ e 164 , respectivamente.

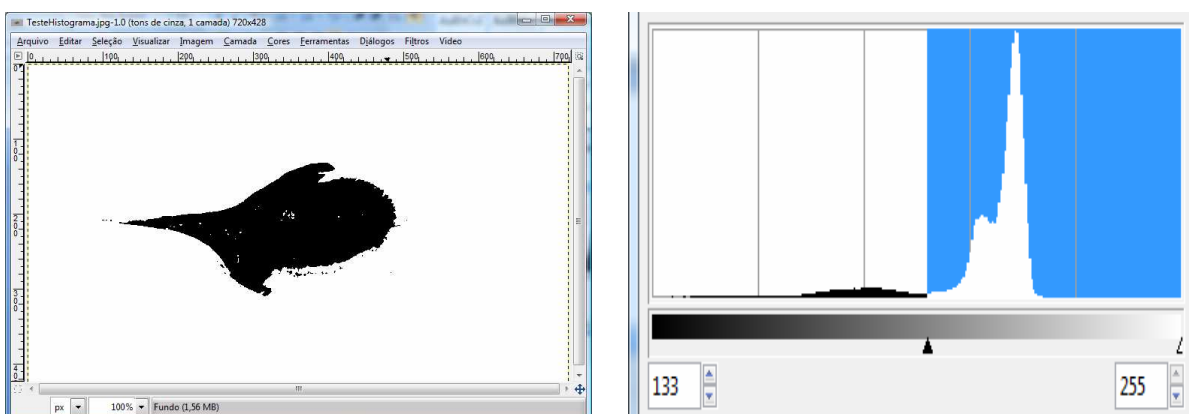


Figura 37 – Imagem segmentada usando limiar $T = 133$.

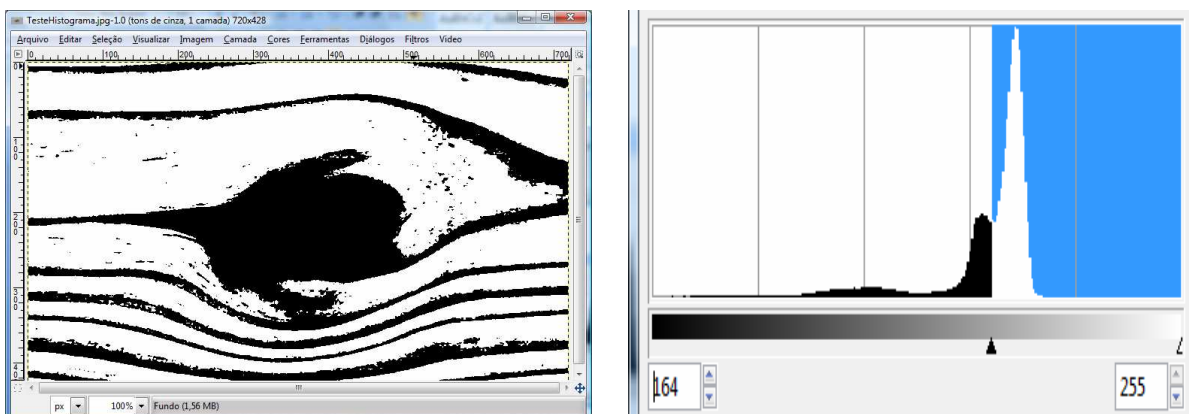


Figura 38 – Imagem segmentada usando limiar $T = 164$.

O valor de limiarização também pode ser determinado pela otimização de certas medidas de separação entre as classes de objetos da imagem, com diminuição dos erros de segmentação entre as classes (PEDRINI e SCHWARTZ, 2008).

No processo de segmentação a escolha do limiar pode ser automático, por meio de cálculos matemáticos ou manual, definido pelo usuário.

A intensidade dos pixels pode ser modelada como funções de densidade de probabilidades, como a função de Gauss, onde a média e a variância são calculadas, em cada distribuição, sendo o limiar escolhido pelo menor erro definido por essas funções (PEDRINI e SCHWARTZ, 2008).

Existem vários outros métodos para a escolha do limiar, resultando na segmentação com erro mínimo entre os picos de duas ou mais funções de probabilidade com distribuição normal, como os propostos por Chow e Kaneko (1972), Rosenfeld e Kak (1982) e Gonzalez e Woods (2002). Nesses métodos, a dificuldade é estimar os parâmetros das distribuições normais e a incerteza ao se considerar a função de probabilidade como uma distribuição normal.

Em 1978, Ridler e Calvard propuseram um método que selecionava iterativamente o valor de limiar, considerando-se a combinação de modelos de duas distribuições Gaussianas. Após a determinação de um valor inicial para o limiar, esse parâmetro é refinado, pela média das distribuições dos níveis de cinza do objeto e do fundo. Esse processo é contínuo, até o momento em que a diferença entre os limiares T torna-se pequena. Esse método foi alterado por Lloyd (1985), para a seleção iterativa do limiar.

Otsu (1979) propôs uma técnica para otimização de parâmetros, como variância do histograma, soma de erros quadráticos, entropia e agrupamento médio. Nesse método de binarização, o limiar é calculado automaticamente e consiste em separar os níveis de cinza em duas classes, uma recebendo o nível de cinza do objeto e o outro, do fundo, sendo que cada classe possui suas próprias médias e desvios-padrão. Esse método apresenta bom desempenho em imagens com maior variância de intensidade, mas o histograma da imagem é bimodal (PEDRINI e SCHWARTZ, 2008).

Enfoque similar ao de Otsu (1979) foi proposto por Pun (1980), baseado na maximização da entropia da imagem, com a divisão do histograma em duas

distribuições de probabilidade, uma representando o objeto e a outra, o fundo. Em 1982, Johannsen e Bile apresentaram um método semelhante ao de Pun (1980), também com a divisão do histograma em duas partes, mas com um limiar que minimizava a interdependência entre as duas classes propostas (PEDRINI e SCHWARTZ, 2008).

B. Limiarização local

Quando o único limiar usado na segmentação de uma imagem não apresenta bons resultados, a limiarização local é a alternativa mais adequada. Os limiares locais são determinados pela análise da intensidade dos pixels em uma região da imagem. A média dos valores de intensidade em uma vizinhança local da imagem é uma medida estatística simples que permite o cálculo de um limiar local (PEDRINI e SCHWARTZ, 2008).

Yasuda et al (1980) propuseram um método onde as escalas de níveis de cinza são expandidas antes de uma suavização não-linear que preserve as bordas. No processo de suavização, cada *pixel* é substituído pela média de seus oito vizinhos e, finalmente, a imagem é binarizada (PEDRINI e SCHWARTZ, 2008).

No método de Niblack (1986), o valor do limiar de um *pixel* foi baseado na média local e no desvio-padrão calculados sobre uma vizinhança. Em 2000, esse método foi alterado por Sauvola e Pietaksinen, na tentativa de melhorar alguns aspectos, como imagens de documentos com iluminação inadequada, onde o limiar se adapta de acordo com a média local e o desvio-padrão sobre uma janela (PEDRINI e SCHWARTZ, 2008).

4.8.4.2. Segmentação de regiões

Os métodos de segmentações de regiões detectam regiões diretamente nas imagens, ao invés de reconhecer as bordas que limitam essas regiões. Uma região é formada por grupos de pontos com propriedades similares, como intensidade de cinza, cor, informação semântica ou textura (PEDRINI e SCHWARTZ, 2008).

A segmentação baseada em *crescimento de regiões* agrega pixels semelhantes em regiões. A partir de um conjunto de pixels, chamado de sementes, as regiões crescem pela anexação de outros pixels semelhantes. Os pixels sementes podem ser escolhidos de maneira aleatória ou selecionado (PEDRINI e SCHWARTZ, 2008).

Segundo Nock e Nielsen (2004), *crescimento de regiões*, ou *Region Growing*, ou ainda *Region Merging* é um método de segmentação que usa a variação da intensidade dos pixels e a proximidade geométrica entre eles para produzir regiões.

Os pixels podem ser agrupados por proximidade de valor escalar ou desvio padrão. Com valor escalar, é feita uma normalização de todos os pixels e agrupa-se pixels com valores próximos, formando assim uma região de interesse. Na Figura 39, os pixels com valores não distantes de 10 são agrupados em três regiões.

23	33	50	56
25	26	51	55
120	120	130	122
122	123	125	128

23	33	50	56
25	26	51	55
120	120	130	122
122	123	125	128

Figura 39 – Exemplo de crescimento de região.

Outro tipo de segmentação, a baseada na *divisão de regiões*, subdivide as regiões não homogêneas em áreas menores, sendo que esse processo termina quando todas as regiões satisfazem o critério de similaridade (PEDRINI e SCHWARTZ, 2008). Esse critério foi descrito por Haralick e Shapiro (1992), onde uma região é definida como um conjunto de pixels conexos pela média e variância do conjunto, sendo essas grandezas atualizadas a cada novo pixels agregado.

Uma imagem pode ser dividida em regiões homogêneas pela representação *quadtree*, baseada na decomposição recursiva e regular da imagem em quadrantes (PEDRINI e SCHWARTZ, 2008).

As duas primeiras técnicas citadas podem ser combinadas, a fim de reunir as vantagens de cada uma delas, sendo muito útil na segmentação de imagens complexas. Alternativamente, a imagem poderia ser subdividida em um conjunto de regiões arbitrárias e disjuntas (PEDRINI e SCHWARTZ, 2008).

Na segmentação por divisor de águas, a imagem a ser segmentada é interpretada em uma topografia, onde as intensidades dos pixels correspondem a valores de altitude ou elevação dos pontos, formando uma superfície composta por vales e picos de diferentes tamanhos (PEDRINI e SCHWARTZ, 2008).

Essa técnica pode ser afetada por vários fatores, pois o processo é sensível à presença de ruído, que pode estar presente na forma de valores mínimos ou máximos da imagem, comprometendo a qualidade. Irregularidades nas bordas podem levar a vazamentos (PEDRINI e SCHWARTZ, 2008).

4.8.4.3. Distância Euclidiana

A distância euclidiana funciona de modo a tomar as diversas dimensões de um ponto e compará-las com outro, no caso o centróide, pela equação, onde “n” e “m” representam os pontos ou pixels e as coordenadas (x,y) (PEDRINI e SCHWARTZ, 2008).

$$D_E(n, m) = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (15)$$

4.8.4.4. Operações morfológicas de abertura e fechamento para eliminar artefatos

Operações morfológicas é o termo usado para se referir a operações que alteram a forma de imagens binárias usando filtros (também conhecidos como kernels ou elementos estruturantes).

Segundo Gonzalez e Woods (2000), estas operações são derivadas de duas operações básicas: Erosão e Dilatação, que em linhas gerais resultam em “encolhimentos” e “alargamentos” dos objetos ou áreas de interesse da imagem.

A operação de abertura é formada por N erosões seguidas por N dilatações, Onde N é o número de iterações. Esta operação é usada para eliminar elementos menores (ou mais finos) que os elementos de interesse.

A erosão é usada para fechar buracos e reentrâncias nos objetos de interesse, e consistem em N dilatações seguidas de N erosões, conforme Figura 40.

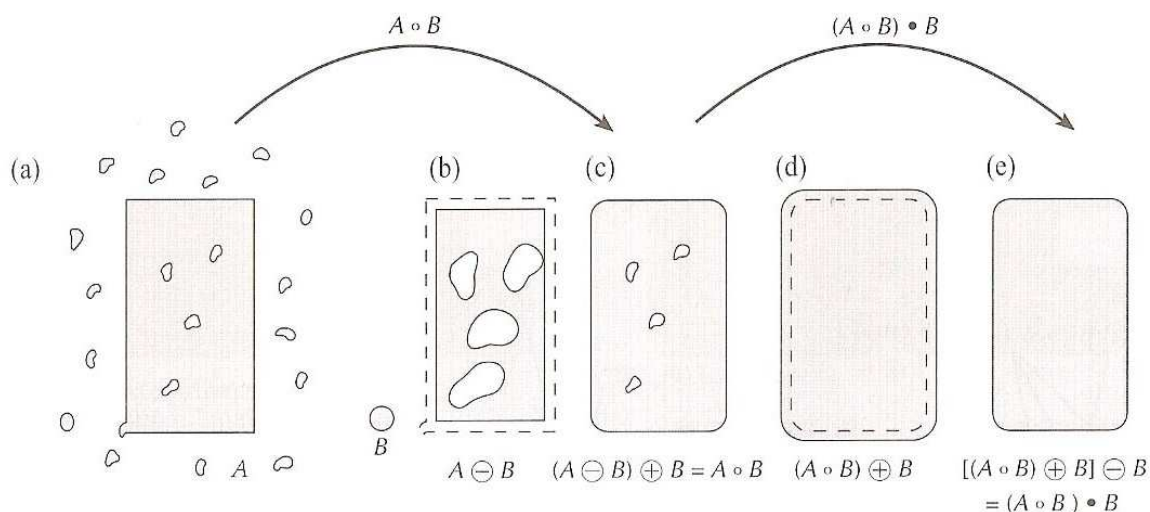


Figura 40 – Exemplo de operação morfológica; (a) imagem original ruidosa; (b) resultado da erosão; (c) abertura de A; (d) resultado da dilatação do resultado da abertura; (e) resultado final mostrando o fechamento da abertura.

Fonte: GONZALEZ E WOODS, (2000).

4.8.4.5. Operações lógicas

As principais operações lógicas utilizadas em processamento de imagens são AND ($f_1(x,y) \text{ AND } f_2(x,y)$), OR ($f_1(x,y) \text{ OR } f_2(x,y)$), XOR ($f_1(x,y) \text{ XOR } f_2(x,y)$) e NOT ($\text{NOT } f_1(x,y)$).

A operação AND produz o valor 1 na imagem resultante quando os pixels correspondentes nas duas imagens de entrada possuem valor igual a 1. A operação XOR produz 1 quando apenas um dos pixels (mas não ambos) possui valor 1, caso contrário, produz 0. O resultado da operação OR é 1 quando pelo menos um dos pixels das imagens é igual a 1. A operação NOT inverte o valor do pixel na imagem.

As operações lógicas podem ser utilizadas para combinar informações entre as imagens ou extrair regiões de interesse.

Além de processamento pixel a pixel, as operações lógicas utilizam as operações com máscaras.

4.8.5. Reconhecimento e interpretação

O processo de reconhecimento visa a extração de características ou propriedades que possam ser utilizadas na discriminação entre classes de objetos, bem como atribuir um significado ao conjunto de objetos reconhecidos.

A análise de textura é uma das técnicas mais importantes para o reconhecimento e interpretação de objetos.

A textura é uma propriedade importante na percepção de regiões e superfícies, contendo informações sobre a distribuição espacial das variações de tonalidade locais em valores de pixels que se repetem de maneira regular ou aleatória ao longo do objeto ou imagem.

Não há uma definição geral para textura, tal dificuldade é refletida pelo grande número de métodos de análise de texturas encontrados na literatura. Segundo Haralick (1973), pode-se definir textura a partir de medidas de uniformidade, densidade, aspereza, regularidade e intensidade, dentre outras características da imagem. A textura é caracterizada como um conceito bidimensional, onde uma dimensão contém as propriedades primitivas da tonalidade e a outra corresponde aos relacionamentos espaciais entre elas.

Existem várias abordagens para análise de textura, entre elas, as mais amplamente usadas e reconhecidas são as abordagens estatísticas, que utilizam um conjunto de medidas estatísticas locais para representar uma imagem texturizada.

Um dos métodos estatísticos mais utilizados para análise de textura, proposto por Haralick, (1973), utiliza estatísticas baseadas na matriz de co-ocorrência dos níveis de cinza de uma imagem. Cada elemento que constitui a matriz representa a frequência com que um pixel de nível de cinza X e outro de nível de cinza Y ocorrem na imagem, separados por uma distância dx de linhas e dy de colunas. Conseqüentemente, a distribuição dos níveis de cinza dos pixels pode ser descrita por estatísticas de segunda ordem como a probabilidade de dois pixels terem um determinado nível de cinza ocorrendo com um relacionamento espacial particular.

Essa abordagem é baseada na suposição de que a informação textural está contida na relação de distribuição espacial média ou global dos níveis de cinza na imagem. A informação de textura pode ser especificada usando matrizes de dependência espacial dos níveis de cinza computados em vários ângulos (0° , 45° , 90° e 135°) e distâncias.

A seguir, é feita a normalização dessas matrizes, onde constantes de normalização são definidas para cada ângulo percorrido. Desse modo, essas matrizes podem ser utilizadas para diversos cálculos estatísticos de segunda ordem, como no caso da extração de características de Haralick.

As características das imagens são obtidas através do cálculo das medidas estatísticas de segunda ordem sobre a matriz de co-ocorrência, gerando o vetor de características (feature vector). Características baseadas em textura têm se mostrado eficientes para a análise e classificação de imagens. Essas medidas são utilizadas como diferenciação de uma região para outra, mostrando ser uma assinatura de um padrão definido pela região em estudo (HARALICK, 1973).

Dentre as treze medidas estatísticas propostas por Haralick, duas foram utilizadas neste trabalho, no sentido de identificar os nós carizados:

1) Contraste (CON): medida da quantidade de variação local de níveis de cinza em uma imagem segundo Equação (X).

$$Contraste = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} p_{ij} (i - j)^2 \dots\dots\dots(16)$$

2) Entropia: A entropia ou grau de dispersão de níveis de cinza mede a quantidade de variação local da imagem, segundo Equação (X).

$$Entropia = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} p_{ij} (\log p_{i,j}) \dots\dots\dots(17)$$

Para as equações acima, G é a quantidade de níveis de cinza, P_{ij} é a matriz de co-ocorrência na posição ij, i corresponde à linha da matriz e j a coluna.

De acordo com Baraldi e Parmiggiani (1995), somente seis propriedades contidas nas texturas são mais relevantes: segundo momento angular, entropia, contraste, variância, correlação e homogeneidade.

O segundo momento angular, também chamado de energia, caracteriza a uniformidade de uma textura. Em uma textura áspera, poucos elementos da matriz normalizada são diferentes de zero e estão próximos de um. A entropia expressa a desordem contida na textura. Na imagem não uniforme, as entradas apresentam valores próximos de zero e um, resulta em valores altos, mas não normalizados, o que ocorre na medida de segundo momento angular.

O contraste é caracterizado pela diferença entre os tons de cinza. No baixo contraste, ocorre pequena diferença entre os níveis de cinza dos pixels de uma região próxima à imagem. Esses baixos valores de contraste ocorrem quando há grande concentração de elementos com valores significativos em torno da diagonal principal.

4.9. Utilização de PID na classificação de diferentes materiais.

A utilização do processamento digital de imagens na seleção e classificação de diferentes materiais apresenta grande potencial e muitos pesquisadores têm estudado e desenvolvido *softwares* que auxiliam nessa atividade.

Vários trabalhos relataram a utilização de *softwares* já existentes no processamento de imagens digitais.

Spósito et al. (2004) utilizaram o *software* SIARCS, que auxiliou na avaliação da ação do fungo causador da mancha preta em frutos cítricos. O SIARCS foi novamente utilizado por Cruz et al. (2008), com o objetivo de comparar esse classificador com um algoritmo baseado na emissividade das bandas do verde e do vermelho (SEROBIN), na avaliação de coberturas proporcionadas pela semeadura de leguminosas e de gramíneas, sem haver diferenças estatísticas entre os dois métodos.

Teixeira et al. (2006) utilizaram um scanner para a obtenção das imagens de plântulas de milho, que foram submetidas às ferramentas do programa Scil-image.

Rall e Ballarin (2007), com o auxílio dos *softwares* *Idrisi* e *Image Tool*, realizaram a segmentação e classificação supervisionada de anéis de crescimento de *Pinus Taeda* L.

Zabot et al (2008) capturaram imagens de plântulas de feijão com o auxílio de uma câmera digital e foram processadas pelo programa Sigma Scan Pro v. 5.0,

Jandel Scientific. Nesse mesmo ano, Oliveira et al. (2008) desenvolveram um método para a detecção de defeitos na madeira de *Pinus*, onde as imagens eram captadas com o auxílio de uma câmara tipo *line scan* e processadas para caracterização de cor e textura, como suavidade, aspereza e regularidade. Os autores utilizaram redes neurais e máquinas de vetor de suporte e verificaram que imagens em níveis de cinza apresentaram desempenho mais competitivo em relação ao sensor colorido, de maior custo.

Entretanto, vem sendo relatado o desenvolvimento de vários *softwares* para a resolução de problemas específicos.

Sena Jr. et al. (2001) desenvolveram um software que auxiliou na análise de imagens digitais de milho atacado pela lagarta do cartucho. Nesse mesmo ano, Prates e Fernandes estudaram a expansão das lesões causadas por *Bipolaris sorokiniana* em folhas de trigo, com o auxílio do software desenvolvido para esse fim e que foi denominado AreaScan.

Existem poucos trabalhos em análise de imagens digitais de madeiras, com o desenvolvimento de softwares que classifiquem essa madeira.

Koivo et al. (1989) desenvolveram um algoritmo para classificar nove classes de defeitos em carvalho vermelho.

Kauppinen (1999) desenvolveu um classificador para seis tipos de defeitos de tábuas de *Pinus*, utilizando histograma das bandas vermelha, verde e azul, com 34% de erro nas classificações. Esse alto índice de erros pode ter ocorrido devido à dificuldade de classificar e diferenciar alguns dos defeitos propostos. Um dos defeitos com maior dificuldade de serem detectados e reconhecidos foram os nós cariados.

Kline et al. (2003) desenvolveram uma máquina com múltiplos sensores a fim de melhorar a taxa de acertos na diferenciação de defeitos, em relação à máquinas de somente um sensor. Os autores utilizaram um câmara RGB e mecanismos de geração de imagens por raio-X e laser e, com isso, a taxa de acerto subiu de 48% para 63%. Quoirin (2004) desenvolveu um software para o diagnóstico de imagens de madeira, capturadas por tomografia de raios-X, como técnica não-destrutiva de avaliação de defeitos.

Khoury et al. (2006), desenvolveram redes neurais artificiais usando percentis das bandas vermelha, verde e azul, como Kauppinen (1999), para avaliação de

defeitos de madeira serrada de eucalipto e, dependendo do tamanho de blocos da imagem, obtiveram taxas de exatidão de 83,1% (blocos de 64x64 *pixels*) e 76,6% (32x32 *pixels*).

Gomes et al. (2008) desenvolveram um classificador de imagens para a identificação de defeitos de madeira serrada de eucalipto, usando linguagem C+ e um conjunto de bibliotecas de funções fornecidas pelos fabricantes da câmara. Quando os autores utilizaram as normas da ABNT, a taxa de acerto foi de 64,3% e quando utilizaram padronização de uma serraria comercial, essa taxa subiu para 81%.

No âmbito comercial, o *WoodEye*, da marca *Innovativ Vision* é um equipamento dotado de um *scanner* óptico, baseado em espectro de luz e laser que capta a imagem da madeira em tempo real que passa através do equipamento por uma esteira. A imagem é processada digitalmente e o *software* do equipamento classifica o defeito, aceitando-o ou cortando a madeira de tal modo a eliminá-lo ou reduzir a sua presença. Segundo Denadai (2010), representante da *Innovativ Vision* no Brasil, esse equipamento não existe em nosso país e seu custo inicial é de, aproximadamente, 500 mil dólares.

Assim, faz-se necessário o desenvolvimento de equipamentos que realizem tarefas semelhantes, porém a um menor custo, condizente com a realidade das pequenas e médias serrarias no Brasil.

5. MATERIAL E MÉTODOS

Na identificação dos defeitos (nós, medula e bolsa de resina) da madeira serrada (tábuas) de *Pinus taeda* L., utilizando o processamento de imagens digitais, para a consecução dos objetivos de definir técnicas e revelar parâmetros para a madeira, foi delineado um método composto por sete etapas distintas de operacionalização, a saber:

1. coleta e processamento mecânico das tábuas;
2. classificação manual das tábuas;
3. montagem do ambiente para aquisição das imagens;
4. aquisição das imagens das tábuas;
5. pré-processamento das imagens;
6. segmentação das imagens;
7. reconhecimento e interpretação;
8. classificação.

As três primeiras etapas constituíram-se como preparatórias para a aquisição das imagens (quarta etapa) e seu posterior processamento.

O processamento das imagens, a partir da quinta etapa, foi realizado com o uso de um software desenvolvido na linguagem Java, com o kit de desenvolvimento J2SE 5.0 Java Developer Kit (JDK), utilizando como interface para desenvolvimento o software Netbeans versão 6.8, biblioteca Java Advanced Imaging (JAI) e os softwares Fiji e ImageJ, disponibilizados gratuitamente nos sites dos fabricantes.

A segmentação das imagens foi realizada utilizando-se os métodos de crescimento de regiões, limiarização, operação binária XOR e operações morfológicas.

O reconhecimento e interpretação das imagens foram realizados a partir da determinação de características morfológicas (área do objeto, comprimento da tábua, largura média da tábua, perímetro, comprimento do objeto, largura máxima da medula e fator de forma do objeto), cromáticas, texturais (entropia e contraste) e estruturais.

A classificação final, obtida a partir dos defeitos detectados, foi comparada com aquela obtida na classificação manual.

As etapas são detalhadas a seguir.

5.1. Coleta e processamento mecânico das tábuas

O trabalho foi desenvolvido com madeira de *Pinus taeda* L. do Horto Florestal no município de Manduri- SP (latitude 23°00' sul, longitude 49°19' oeste e altitude de 700m). Foram amostradas, ao acaso, seis árvores com aproximadamente 37 anos de idade do talhão escolhido e posteriormente desdobradas cada uma em três toras, com cerca de 225 cm de comprimento.

As toras foram desdobradas em tábuas e pranchas na serraria do próprio Horto Florestal de Manduri. De cada tora foi retirada um prancha central (Figura 41), com aproximadamente 225 cm de comprimento, 6 cm de espessura, e largura variável, resultando em um total de 18 pranchas, que foram utilizadas em outros estudos.

As tábuas, material de estudo deste trabalho, foram retiradas das costaneiras laterais esquerdas e direitas das toras. A quantidade de tábuas retiradas era dependente do diâmetro da tora de origem. No total foram obtidas 84 tábuas com dimensões aproximadas de 225 cm de comprimento, 2,5 cm de espessura e larguras variadas, de acordo com o diâmetro das toras de origem.




Figura 41 - Tora desdobrada.

A madeira foi secada em um secador industrial da Madeireira Makenboy – Manduri, até atingir a umidade nominal de equilíbrio de 12%.

Na marcenaria da Faculdade de Ciências Agrônômicas da UNESP - Botucatu/SP, as tábuas foram aplainadas, tiveram seus comprimentos retificados para 200 cm, com a manutenção de suas larguras variáveis entre 13,5 e 32,6 cm (média de 21,5 cm). Logo após, foram escolhidas aleatoriamente 84 tábuas para o estudo. Todas as tábuas foram identificadas com um número seqüencial de 1 a 84 e mantida, adicionalmente, uma codificação com informações dos locais de sua retirada, considerando-se a árvore, a tora e a localização da tábua.

A codificação era composta de letras e números que, em qualquer momento, se necessário, poderão ser associadas às propriedades encontradas e à localização na árvore.

O primeiro dígito indicava a árvore e o segundo dígito, após a barra, indicava a tora (Figura 42).




Figura 42 – Indicações de árvore e tora.

Nas tábuas, foi acrescentada uma identificação que representava o desdobro das costaneiras laterais das toras. A letra “D” ou “E” representavam o lado direito e esquerdo da tábua, respectivamente, seguida do dígito de cada tábua, retirada a partir das costaneiras laterais da tora, sempre do interior para o exterior, adicionando-se um número seqüencial (Figura 43).




Figura 43 – Desdobro das tábuas.

Assim, por exemplo, uma tábua com a nomenclatura “2/1 D1” tratava-se de uma tábua retirada da árvore “2”; da tora “1”; da posição “D” em relação à largura, 1ª tábua a partir da medula para a casca.

A Figura 44 apresenta as 84 tábuas numeradas de 1 a 84, com destaque

para a de número 40, com as informações “1/1 D1” (árvore 1, tora 1 e primeira tábua a direita).



Figura 44 – Conjunto das 84 tábuas, numeradas seguindo o padrão estabelecido

5.2. Classificação manual das tábuas

Antes de iniciar o processamento das imagens digitais, foram realizados os trabalhos de classificação manual das tábuas, seguindo a norma NBR 11.700 – Madeira serrada de coníferas provenientes de reflorestamento para uso geral.

Esta classificação manual se fez necessária, pois, a partir dos resultados obtidos, pode-se aferir a eficiência do software de visão artificial desenvolvido, além de fornecer parâmetros para a avaliação da aplicabilidade da norma e informações sobre os possíveis defeitos encontrados nas tábuas.

A identificação dos defeitos foi executada visualmente, as aferições foram realizadas com uma régua milimétrica e a classificação das tábuas foi feita com uso da Tabela 2, já apresentada.

Foi desenvolvida uma planilha eletrônica, por meio do software Microsoft Excel, para auxiliar nos cálculos principalmente das porcentagens dos nós, medula e bolsa de resina. A Figura 45 ilustra o formato geral da planilha.

Relação de amostras, mensuração e classificação, segundo Norma ABNT 11.700 (tábuas de 2000 mm de comprimento)													
Num.	Ref. tábuas	Largura (mm)	Diâmetro do Nó (mm)					Bolsa de resina		Medula		Espora <3mm	Classe
			Firme	Cariado	Gravata	Vazado	Grupo	Largura (mm)	Comprim. (mm)	Largura (mm)(1)	Comprim. (mm)		
1													
		Totais %	0	0	0	0	0	0	0	0	0	0	0

Figura 45 – Planilha no Microsoft Excel para classificação de tábuas de *Pinus*.

5.3. Montagem do ambiente para aquisição das imagens

Sabendo-se que a iluminação é um fator de grande importância, pois a homogeneidade da luz proporciona um bom contraste, igualdade das condições das tábuas e um posterior processamento mais eficiente, montou-se uma sala onde todas as janelas e frestas foram tampadas com plástico preto, impedindo que qualquer fonte de luz externa interferisse na iluminação artificial montada para a aquisição.

Foi montada a estrutura para aquisição das imagens, onde foi primeiramente fixado um pano azul como fundo das imagens – a cor azul foi escolhida devido ao contraste com as cores das tábuas, facilitando sua retirada posterior por meio de PID. Por trás do pano foram embutidos na parede três parafusos em formato de gancho circular, sendo dois na mesma altura, a 90 cm do piso, para suporte das tábuas e um na lateral, para fixação com alfinete da tábua contra a parede, não permitindo que ela se projetasse à frente. Também foi construída uma estrutura com caibros e tábuas, para o suporte da iluminação, conforme ilustra a Figura 46.




Figura 46 – Vista posterior da estrutura em madeira para suporte da iluminação (dimensão em metros)

As lâmpadas (fixadas às tábuas da estrutura de iluminação) foram posicionadas equidistantes em relação à altura da tábua. Sempre se objetivou a igualdade na iluminação, sem a produção de sombra, pois quanto mais altas as lâmpadas superiores ou mais baixas as inferiores, maior a sombra produzida na borda da tábua. Este cuidado foi necessário, pois a presença da sombra poderia dificultar o PID posterior.

Foram utilizadas quatro lâmpadas fluorescentes de 40 W (Sylvania), duas em cada tábua da estrutura de iluminação, modelo Luz do Dia T12, com 1,20 m de comprimento. Para cada duas lâmpadas, foi instalado um reator eletrônico (RCG), modelo RE 240 CG, bivolt 127 e 220 volts e 50 e 60 Hz.

5.4. Aquisição das imagens das tábuas

As imagens foram adquiridas com uso de câmera fotográfica marca Lumix, do fabricante Panasonic, modelo DMC-LZ26, com resolução máxima de 6 megapixels e zoom óptico de 6x.

Todas as imagens foram adquiridas com a resolução de 6 megapixels,

com dimensões 3072 x 2048 pixels, gerando arquivos do tipo “jpeg”, com tamanho aproximado de 2 megabytes.

Foi acionado o zoom com 0,1x, visando desligar o efeito da lente grande angular, presente em algumas câmeras, que distorce as linhas horizontais, na posição central da foto. Pode-se perceber a distorção causada no topo da imagem da tábua (Figura 47a), sob efeito da lente grande angular, e na Figura 47b, sem o efeito da lente e com o topo da tábua reto, sem distorção.




Figura 47 – Deformação nas imagens: a) Imagem com deformação; b) Imagem sem deformação

O tripé (marca Mirage, modelo Lander) para fixação da câmera fotográfica, foi graduado com 1 m de altura e posicionado em até três posições (1, 2 e 3), conforme ilustrado na Figura 48, para a aquisição das imagens da primeira metade (lado esquerdo da tábua), medindo 1 m, da segunda metade (lado direito da tábua) e da tábua inteira, respectivamente. Para tanto, a estrutura de iluminação foi posicionada a 1,07 m e a câmera, com tripé, a 1,1m da tábua (posições 1 e 2) e a 3 m (posição 3), conforme mostram as Figuras 49.

A aquisição das imagens em duas metades de cada tábua visou a produção de arquivos com maior concentração de *pixels* e a melhor visualização de defeitos, devido a maior proximidade da câmera em relação à tábua.




Figura 48 – Vista superior do arranjo geral adotado na aquisição das imagens.




Figura 49 – Esquemas da aquisição das imagens. Arranjo geral.

A Figura 50 mostra o estúdio, que permitiu uma boa iluminação em um ambiente controlado.




Figura 50 – Estúdio montado para a aquisição das imagens.

Cabe ressaltar que os ajustes das distâncias entre as lâmpadas, tanto na vertical como na horizontal, bem como o posicionamento da estrutura de iluminação, foram adotadas após uma série de medições de iluminância, que buscou a uniformidade da densidade do fluxo luminoso em vários pontos da superfície da tábua. Descobriu-se, durante o experimento, que as lâmpadas fluorescentes utilizadas apresentavam uma maior emissão de luz na parte central e uma menor, em seus extremos. Para minimizar esse efeito, o melhor arranjo foi obtido com as lâmpadas afastadas horizontalmente de 0,22 m.

A medição da iluminação foi realizada com um luxímetro digital, modelo Thal 300 (Multivisi), gentilmente cedido pelo Departamento de Botânica do Instituto de Biociências - Unesp – Botucatu.

Para a realização das medições, primeiramente a tábua foi demarcada, com fita adesiva, de 100 em 100 mm, nas direções horizontal e vertical, formando quadrículas (4 linhas na horizontal e 21 linhas na vertical) e resultando em 84 pontos de medição, conforme ilustra Figura 51.



(a)

(b)

Figura 51 – Avaliação da iluminância. a) vista geral das regiões de medição na tábua; b) posicionamento do luxímetro para medição.

5.5. Pré-processamento das imagens

Esta etapa foi composta pela extração (corte) do fundo da imagem, dispensando com isso grande parte desnecessária da imagem original.

Considerando-se que as tábuas sempre estavam posicionadas no centro vertical da imagem, não ocupando mais de dois terços da mesma, foi possível dispensar o terço superior e inferior, sem prejuízo dos resultados e com ganho de desempenho do software, pois exigiu pouco processamento.

5.6. Segmentação das imagens

Nesta etapa as imagens foram tratadas a fim de que os objetos de interesse (nos, medula e bolsa de resina) fossem separados do restante da imagem. Para isso, utilizaram-se os métodos de segmentação por crescimento de regiões e por limiarização, operação binária XOR e operações morfológicas.

5.6.1. Segmentação utilizando crescimento de regiões

O método de crescimento de regiões foi aplicado na banda verde, após avaliação qualitativa do histograma, das três bandas no conjunto de imagens disponíveis, ter demonstrado que ela trazia melhores resultados que as outras.

O software começava a análise em um ponto da imagem, (chamado de pixel semente), usualmente no canto superior esquerdo e ia “expandindo” pixel a pixel. Se o próximo pixel fosse unido aos já computados e não modificasse a média mais que um valor pré-determinado, esse pixel era incluído na região. Se, caso contrário, a média mudasse mais do que o valor pré-determinado, ele seria considerado o início de uma nova região.

A implementação adotada pelo software utilizou um fator de complexidade, para calcular esta diferença, com valor fixado em 10, pois com ele o processo de segmentação produziu os melhores resultados no conjunto de imagens disponíveis.

Este método foi adaptado a partir do código utilizado no software Fiji, já comentado.

Este método foi particularmente importante na segmentação das medulas, que não puderam ser segmentadas diretamente apenas por Threshold, pois os pixels dos lenhos tardios continham valores muito próximos dos da medula.

5.6.2. Segmentação por limiarização (*thresholding*)

O método de segmentação por limiarização (*thresholding*) utilizado foi o *Intermodes*, que pressupõe um histograma bimodal, presente nas imagens utilizadas neste projeto. Na sua versão original o método localiza as duas modas e toma como valor de limiar (*threshold*) o ponto central entre elas.

Na versão utilizada neste trabalho era introduzido um índice relativo (variando entre 0,0 e 1,0), que determinava a posição do limiar entre as duas modas. Assim, por exemplo, usando-se o índice relativo 0,5, resgatava-se o resultado obtido na versão original do método (Figura 52).

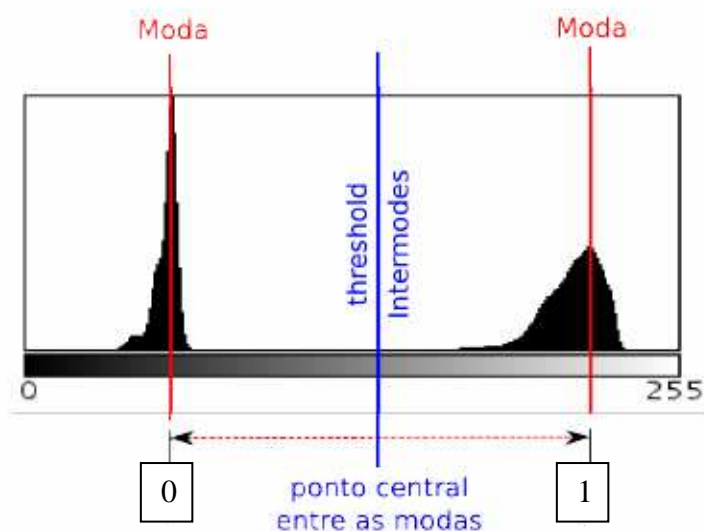


Figura 52 - Intermodos original.

5.6.3. Operação binária XOR

A operação binária XOR incorporou os pixels das duas imagens e ao restante foi atribuído o valor zero, funcionando como uma máscara, ficando visível e colorido apenas os objetos de interesse, para serem reconhecidos e interpretados posteriormente.

5.6.4. Operações morfológicas

Como esse método não foi capaz de eliminar completamente o fundo e, em alguns casos, eliminava parte da região de interesse, foi necessário utilizar operações morfológicas de abertura e fechamento, para eliminar os ruídos na imagem. Para isso, foi utilizado um kernel quadrado, que preserva as arestas dos objetos, como as presentes nas tábuas das imagens utilizadas. O tamanho do kernel escolhido foi 3x3. Alguns testes foram realizados com tamanhos maiores, mas o tempo de processamento foi maior e não houve melhora no resultado.

Na segmentação dos nós, medula e bolsa de resina, os métodos foram testados em diversas combinações.

5.7. Reconhecimento e Interpretação das imagens

Nesta etapa foram mensuradas características morfológicas, cromáticas, texturais e estruturais dos objetos sob análise (nós, medula e bolsa de resina).

5.7.1 Medição de características morfológicas

As medidas morfológicas foram tomadas em pixels e armazenadas em milímetros, usando-se a escala produzida pelo método escolhido pelo usuário do software (“Opções de escala” do software).

Foram implementadas as seguintes medidas morfológicas:

1. Área do objeto.
2. Comprimento da tábua.
3. Largura média da tábua.
4. Perímetro e largura do objeto.
5. Comprimento e largura do objeto.
6. Largura máxima da medula.
7. Fator de forma do objeto.

5.7.1.1 Área do objeto

Área foi calculada a obtendo-se o total de pixels que compunha o objeto multiplicado pela sua área individual.

5.7.1.2 Comprimento da tábua

O comprimento da tábua foi avaliado sobre uma linha central, obtida por união dos pontos médios da largura da tábua, avaliada nos dois extremos do comprimento dela, conforme mostra a Figura 53. Verificou-se o número de pixels e multiplicou-se pelo tamanho destes.




Figura 53 – Esquema de medição do comprimento da tábua.

5.7.1.3 Largura média da tábua

Para medir a largura, foram feitas medições em três pontos ao longo do comprimento da tábua, conforme ilustrado na Figura 54, tomando-se como resultado a média das três larguras obtidas.




Figura 54 – Esquema de medição da largura média da tábua.

5.7.1.4 Perímetro do objeto

Para possibilitar as medições dos objetos (nós, medula e bolsa de resina), seus perímetros externos foram extraídos da imagem. O algoritmo percorreu a imagem do objeto de cima para baixo e da esquerda para a direita, até encontrar um pixel pertencente ao objeto. Quando o encontrou, pesquisou os pixels adjacentes em busca do próximo ponto do perímetro. Este passo repetiu-se até que o primeiro ponto fosse encontrado novamente.

Foram armazenadas todas as coordenadas $(p(i, j))$ dos pixels que fizeram parte do perímetro, para posteriores avaliações.

5.7.1.5 Comprimento e largura do objeto

Para facilitar outras mensurações morfológicas nos objetos, eles foram “enquadrados” em uma caixa de limites.

A caixa de limites é o menor retângulo em que o objeto pode estar contido. Este retângulo foi gerado durante a obtenção do perímetro do objeto e sua largura e comprimento correspondem à largura e ao comprimento do objeto, conforme Figura 55. Foram calculados, a partir dos valores máximos e mínimos das coordenadas i e j , nas direções vertical e horizontal do objeto, respectivamente. A largura do retângulo correspondeu ao diâmetro dos nós.




Figura 55 – Caixa de limites, enquadrando um nó.

5.7.1.6 Largura máxima do objeto

A largura máxima foi medida calculando-se as larguras em todas as posições do objeto e selecionando-se a maior largura obtida. Para fins de otimização, esta medida foi calculada apenas nas regiões que foram classificadas como medula.

5.7.1.7 Fator de forma do objeto

O fator de forma (relação entre a largura e o comprimento) do objeto foi calculado pelo software a partir das informações da caixa de limites.

5.7.2 Medição de características cromáticas

O software implementou as seguintes medidas cromáticas dos objetos:

1. Quantidade de pixels similares ao fundo.
2. Médias (de todas as bandas).
3. Mediana (de todas as bandas).
4. Modas (de todas as bandas).
5. Desvios-padrão (de todas as bandas).
6. Percentil 5% inferior (de todas as bandas).

5.7.2.1 Quantidade de pixels similares ao fundo

A ocorrência de pixels com cor similar ao fundo azul caracterizou um furo na tábua, parâmetro que define o nó vazado.

Primeiramente, calculou-se a média de cada banda em um retângulo do fundo azul utilizado. A seguir, o software comparou estas médias às das três bandas (R, G e B) de cada pixel do objeto. Diferenças inferiores a 40 eram reveladoras da presença do fundo azul e, portanto, de nó vazado.

5.7.2.2 Médias, Medianas, Modas e Desvios-padrão

Estas medidas estatísticas foram extraídas do conjunto de pixels de cada banda, em cada objeto.

5.7.2.3 Percentil 5% inferior

O percentil 5% inferior foi utilizado para detectar as “marcas escuras” que caracterizam os nós cariados. Nos objetos menores que 2000 pixels, utilizou-se o percentil 5% inferior. Em objetos maiores, o programa procurou o percentil que incluísse o número de pixels mais próximo de 1000 na tábua.

5.7.3 Medição de características texturais

Para medição das características texturais o software utilizou-se do método da matriz de co-ocorrência. Ele descreve uma imagem ou uma região de interesse na imagem, relacionando os valores dos pixels com os valores dos pixels vizinhos. Foram utilizados os quatro ângulos descritos por Haralick (1973).

As medidas texturais avaliadas, avaliadas em cada banda, foram entropia e contraste.

5.7.4 Medição de características estruturais

A característica estrutural utilizada foi a porcentagem de borda coincidente com a borda da tábua.

Esta medida detectou objetos que chegavam à borda da tábua. Em alguns casos, eram nós que foram serrados e, em outros, medula. Em vários casos esta medida foi útil para descartar falso-positivos, objetos detectados pelo software que não correspondem a nós, medula e bolsa de resina, principalmente os que apareceram devido as marcas deixadas pelas lâminas da desengrossadeira, durante o processamento mecânico na serraria.

Essa porcentagem foi calculada comparando o perímetro do defeito com o perímetro da tábua. O software contou quantos pontos do perímetro do defeito coincidiavam (ou tinham distância menor que 2 pixels) com o perímetro da tábua. Com os números de pontos coincidentes, calculou-se a porcentagem em relação ao perímetro total do defeito.

As características foram testadas em diversas combinações, objetivando a classificação mais efetiva dos defeitos.

5.8. Classificação das tábuas

A classificação das tábuas, última etapa do processo, foi realizada com base nas prescrições da norma NBR 11700 (ABNT, 1991).

Para tanto, utilizaram-se os objetos segmentados, mensurados e classificados pelo software

O Fluxograma da Figura 56 ilustra o fluxograma para a classificação das tábuas.

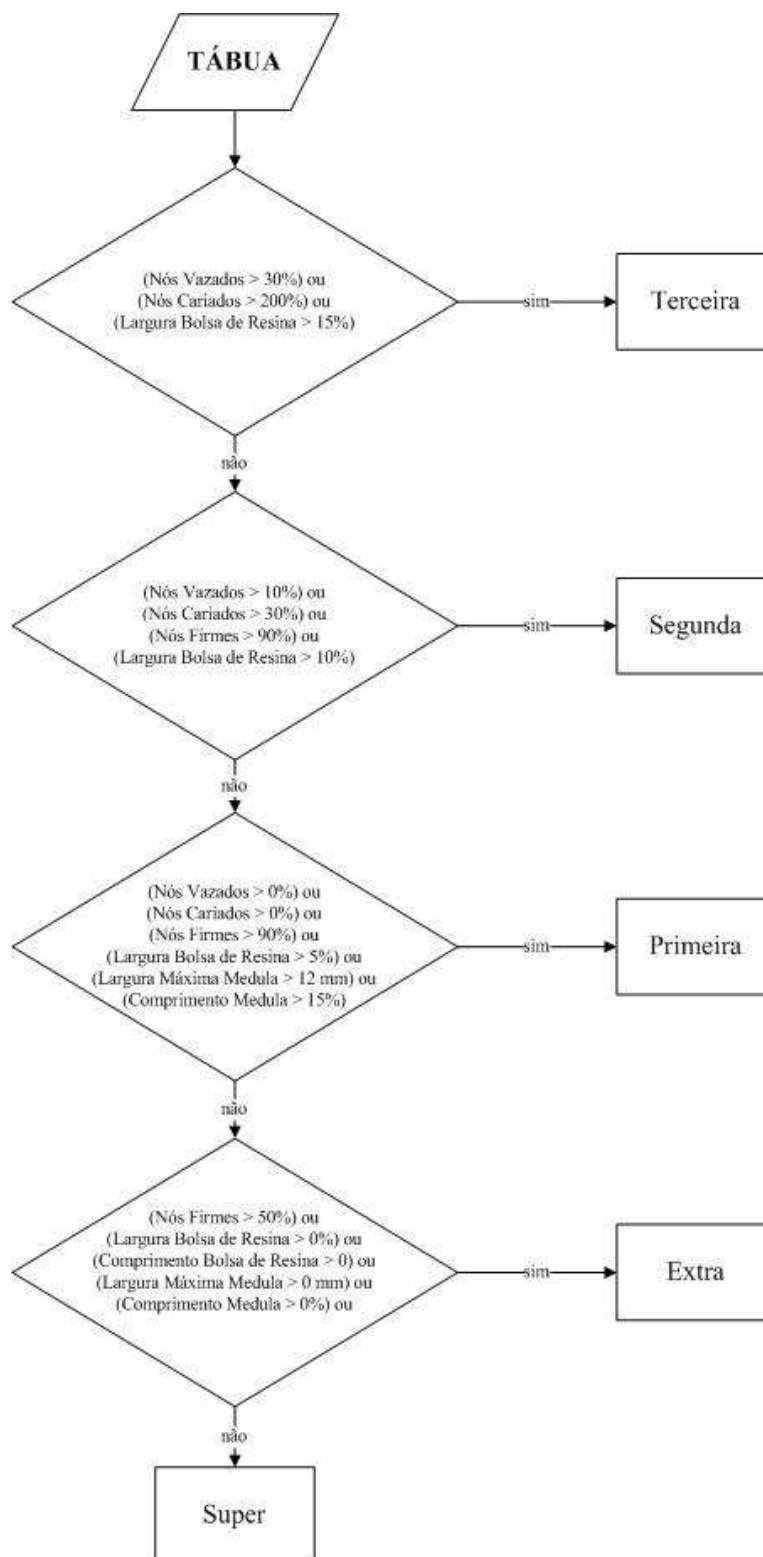


Figura 56 - Fluxograma para a classificação das tábuas.

6. RESULTADOS E DISCUSSÃO

6.1. Iluminação utilizada no estúdio

A iluminação foi avaliada por meio de medição da iluminância em 84 pontos na tábua mais larga e os resultados estão expressos na Tabela 5. A média foi de 972 lx, muito próxima às atingidas pelas quatro linhas horizontais, com um desvio padrão de 2,4 lx.

6.2. Processamento mecânico das tábuas

As dimensões das tábuas estão apresentadas no Apêndice A.

6.3. Classificação manual das tábuas

A Tabela 6 resume o número de tábuas em cada uma das classes de qualidade preconizadas pela NBR 11.700 (ABNT, 1991).

Pode-se notar que a maior ocorrência foi de tábuas de Primeira Classe, com 49%, seguida das classes Segunda e Super. As classes Extra e Terceira não foram encontradas.

Tabela 5 - Medições de iluminância aferidas nos pontos distribuídos na tábua.

P. M.	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	Média		
(lux)	965	970	980	982	979	980	980	968	956	960	960	964	973	980	992	970	974	980	981	950	954	971		
P. M.	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41			
(lux)	965	960	980	978	977	976	980	978	976	980	970	975	984	984	980	978	975	976	978	975	970	976		
P. M.	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60	61	62			
(lux)	970	979	980	982	978	979	978	975	963	965	968	970	964	980	981	985	982	983	984	985	972	976		
P. M.	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83			
(lux)	968	967	965	966	965	966	965	964	964	965	963	964	964	972	969	970	975	976	970	969	970	967		
																						Média Geral (lx):	973	
																							Desvio padrão:	2,4

Nota: P. M.- Ponto de medição na tábua;

Tabela 6 - Classificação das tábuas, segundo ABNT 11.700.

Classe	Ocorrências	Porcentagem
Super	16	19%
Extra	0	0%
Primeira	41	49%
Segunda	27	27%
Terceira	0	0%
Geral:	84	100

Durante a classificação, pode-se perceber que os defeitos mais punitivos, que implicavam no rebaixamento de classe, eram a presença de nós vazados e careados nas tábuas. Esses defeitos não são permitidos nas classes Super e Extra e, na Primeira classe, são permitidos com porcentagens iguais ou inferiores a 10 e 30%, respectivamente. Algumas tábuas com apenas um nó careado foram rebaixadas em duas classes, sendo classificadas como de Primeira classe, conforme mostra a Figura 57 para o caso particular da tábua número 72. A partir desta informação, pode-se perceber que a detecção do tipo de nó é uma operação muito importante e decisiva para a classificação da tábua, devendo ter uma atenção especial no desenvolvimento do software.



Figura 57 – Tábua 72 – enquadramento na primeira classe motivada pela ocorrência de um único nó cariado.

Conforme apresentado na Tabela 7, a partir dos dados da planilha, pode-se perceber que defeitos como Grupo de nós, medula, bolsa de resina e espora raramente foram observados no lote estudado, com baixa frequência, em torno de 1%. A presença de espora, que são nós com diâmetro menor ou igual a 3 mm, segundo a NBR 12.551 (ABNT,

1991), não influencia na classificação, pois sua presença é permitida em todas as classes, não sendo levado em consideração pelo software.

Tabela 7 - Relação de defeitos encontrados e suas ocorrências.

Defeitos	Ocorrências	Porcentagem do total de ocorrências	Média por tábua
Nó Firme	202	51	2,46
Nó Cariado	155	39	1,89
Nó de Gravata	2	1	0,02
Nó Vazado	17	4	0,21
Grupo de nó	2	1	0,02
Medula	10	3	0,12
Bolsa de Resina	8	2	0,10
Total	396	100%	

6.4. Segmentação dos objetos

Para a segmentação dos objetos, foram utilizados as 4 técnicas descritas na metodologia e os melhores parâmetros foram obtidos com as seguintes sequências.

Para a obtenção da imagem da tábua sem o fundo azul, partiu-se da imagem resultante do crescimento de regiões, aplicou-se a segmentação por limiarização - *Intermodes*, com índice relativo igual a 0,2 e, logo após, foram realizadas operações morfológicas de abertura, com duas iterações, e fechamento, com cinquenta iterações.

Para obter a imagem dos nós, partiu-se da imagem da tábua, aplicou-se a segmentação por limiarização - *Intermodes*, com índice relativo igual a 0,6. A seguir, foi realizada uma operação lógica binária XOR com a imagem original da tábua colorida, mantendo apenas os nós segmentados e, finalmente, foram realizadas operações morfológicas de abertura, com duas iterações, e fechamento, com duas iterações.

Para a obtenção da imagem da medula e das bolsas de resina partiu-se novamente da imagem da tábua, aplicou-se a segmentação por limiarização - *Intermodes*, com índice igual a 0,95. A seguir, foi realizada uma operação binária XOR da imagem segmentada da medula com a imagem original da tábua colorida, mantendo apenas a medula e as bolsas de resina. Para eliminar os ruídos foram realizadas operações morfológicas de abertura, com duas iterações e fechamento, com duas iterações.

6.5. Classificação dos objetos segmentados

Foram utilizadas, para a classificação dos objetos, as características morfológicas, cromáticas, texturais e estruturais dos objetos sob análise (nós, medula e bolsa de resina) e os melhores parâmetros testados foram os apresentados na Figura 58.

Pode-se observar todos os passos e decisões tomados até que uma região da tábua que foi segmentada fosse reconhecida e rotulada como um tipo específico de defeito.

O primeiro passo do fluxograma utilizou o fator de forma como a maneira de identificar um tipo de objeto falso-positivo, que ocorreu com frequência nas extremidades da tábua e ao redor de nós grandes e disformes. Ele foi identificado pelo fator de forma acima de 5 (largura mais 5 vezes maior que o comprimento). Os defeitos que possuíam esta característica foram rotulados como falso-positivos e os que não possuíam, seguiram sendo testados nos próximos passos. Assim, falso-positivo foi classificado como objeto que, apesar de segmentado, em função da intensidade dos pixels, não era caracterizado como defeito da tábua.

O segundo passo identificou os nós vazados, pela presença de cor semelhante ao fundo azul.

O terceiro passo separou a medula dos demais defeitos. Como houve alguns casos em que nós foram segmentados na imagem da medula (nó e medula numa mesma imagem), foi incluída a condição “Contraste do Vermelho < 50”, para que estes nós permanecessem para os próximos passos de classificação. Os defeitos que foram separados no terceiro passo ainda foram testados para eliminar falso-positivos.

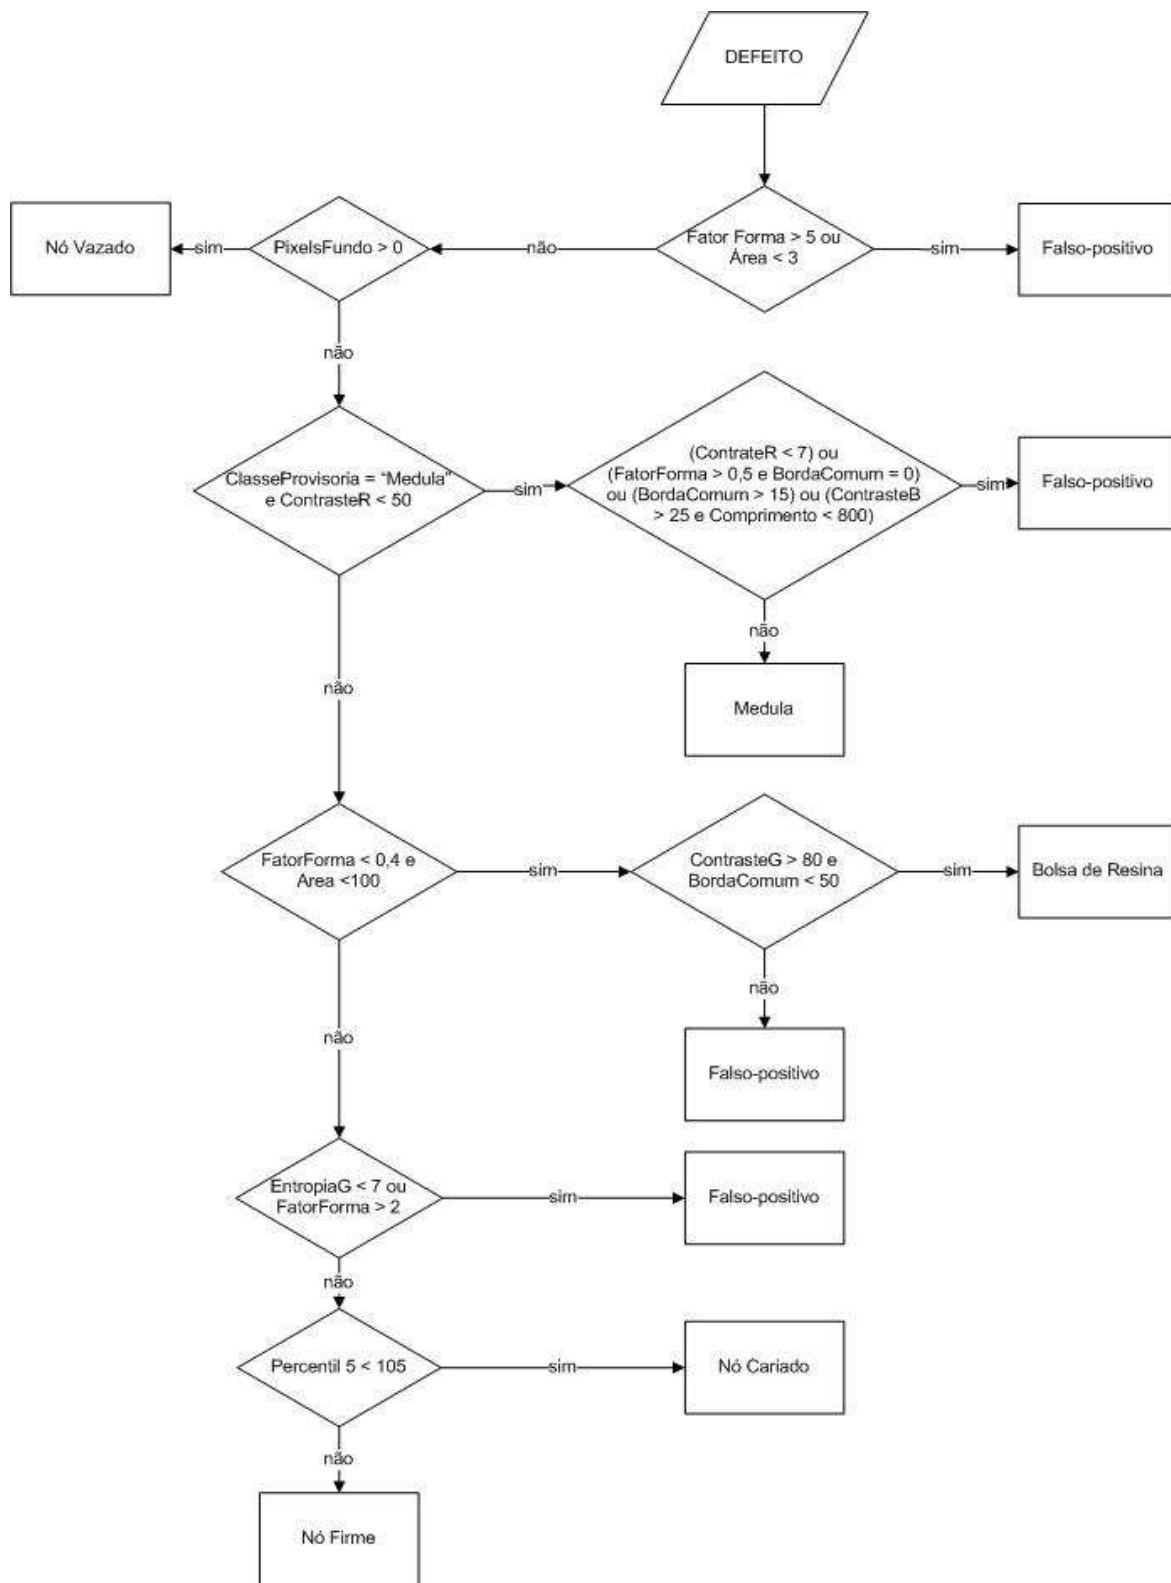


Figura 58 – Fluxograma da classificação dos defeitos

Todos os objetos que tiveram contraste do vermelho menor que 7 ou borda em comum com a tábua maior que 15% foram classificados como falso-positivos. Também foram classificados assim os que combinaram fator de forma menor que 0,5 e ausência de borda em comum com a tábua (por não terem formato característico de medula) e os que combinam Contraste do Azul maior que 25 e comprimento menor que 800. Os demais foram rotulados como medula.

O quarto passo utilizou o fator de forma (menor que 0,4) e a área (menor que 100mm²) para reservar os defeitos que poderiam ser classificados como bolsas de resina. Destes, foram marcados como bolsas de resina apenas os que tiverem contraste no verde maior que 80 e borda em comum com a tábua menor que 50%. O restante foi rotulado como falso-positivo.

O quinto passo descartou os falso-positivos que persistiam, que eram, objetos com áreas pequenas. Foram descartadas as áreas com entropia do verde menor que 7 ou fator de forma maior que 2.

O sexto e último passo tratou da distinção entre nós firmes e nós cariados. A característica escolhida foi o “percentil 5% inferior do vermelho” menor que 105 que detectou pequenas regiões escuras nos nós.

6.6. Imagens e resultados obtidos com o uso do software

Foram obtidos as seguintes imagens e resultados por meio do software.

6.6.1 Corte da imagem original

A partir da imagem original (Figura 59a) foi realizado um corte onde permaneceu somente o terço central, conforme ilustra a Figura 59b.




Figura 59 – Corte da imagem da tábua: a) imagem original; b) imagem cortada no terço central

6.6.2 Segmentação utilizando crescimento de regiões

A implementação adotada pelo software utilizou um fator de complexidade, que foi usado para calcular esta diferença, com valor fixado em 10, pois o processo de segmentação produziu os melhores resultados no conjunto de imagens disponíveis, conforme ilustra a Figura 60.



Figura 60 – Imagem resultante da segmentação por crescimento de regiões.

6.6.3 Segmentação da imagem do fundo

A partir da imagem resultante da segmentação por crescimento de regiões (Figura 61a), foram realizadas as operações de segmentação por limiarização, seguidas das operações morfológicas, que resultou na imagem apresentada na Figura 61b.



Figura 61 – Segmentação para obtenção da imagem da tábua sem o fundo.

6.6.4 Segmentação dos nós

A partir da imagem resultante da segmentação por crescimento de regiões (Figura 62a), foram realizadas as operações de segmentação por limiarização (Figura 62b), operação XOR e operações morfológicas (Figuras 62b e 62c), que resultou na imagem apresentada na Figura 62d.





Figura 62 – Segmentação para obtenção da imagem dos nós: a) imagem obtida por crescimento de região; b) imagem binária segmentada por limiarização dos nós; c) imagem original; d) imagem obtida pela operação XOR (imagem binária com imagem original) e pelas operações morfológicas.

6.6.5 Segmentação da medula

A partir da imagem resultante da segmentação por crescimento de regiões (Figura 63a), foram realizadas as operações de segmentação por limiarização (Figura 63b), operação XOR e operações morfológicas (Figuras 63b e 63c), que resultou na imagem apresentada na Figura 63d.

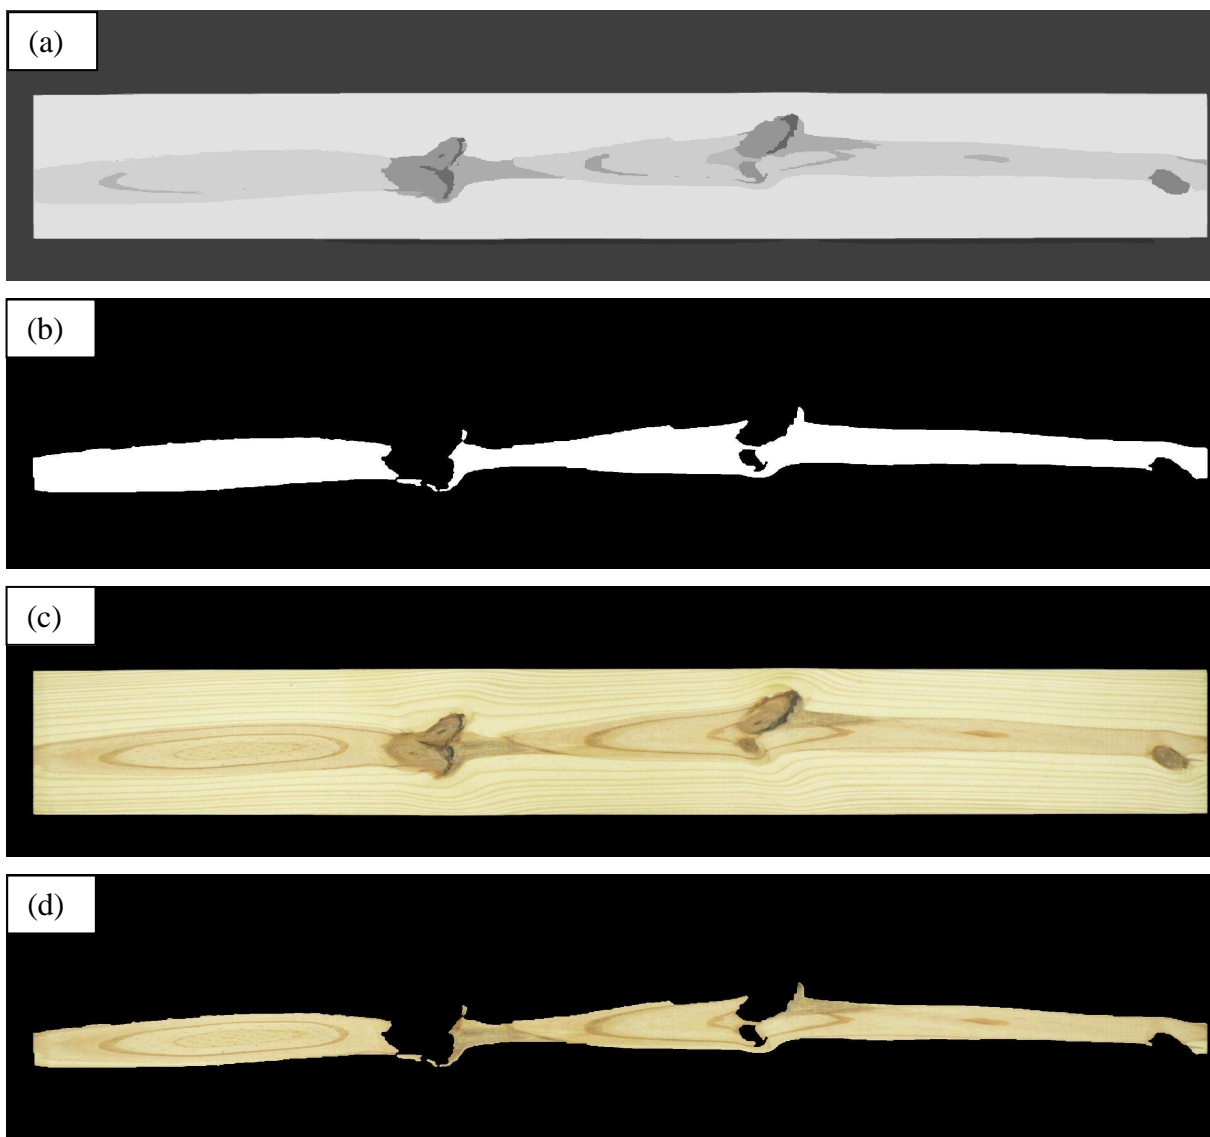


Figura 63 – Segmentação para obtenção da imagem da medula: a) imagem obtida por crescimento de região; b) imagem binária segmentada por limiarização dos nós; c) imagem original; d) imagem obtida pela operação XOR (imagem binária com imagem original) e pelas operações morfológicas.

6.6.6 Extração de características

Foram extraídas todas as características e classificados os defeitos encontrados, conforme mencionado anteriormente, e apresentada em uma planilha pelo software, conforme apresenta a Figura 64.

Defeitos		Tábuas															
Origem	Imagem ...	Classe ...	Rótulo	Área	Diâmetro...	Comprim...	Fator de ...	% de Bo...	Fundo	R Percen...	G Percenti...	B Percen...	R Entropia	G Entropia	R Contraste	G Contra...	B Contra...
01c.JPG	Medula	Medula	1,00	71.738,35	97,35	1.314,27	0,11	1,74	0,00	172,00	147,00	89,00	8,73	9,35	11,17	14,21	18,87
01c.JPG	Medula	Medula	3,00	45.397,51	87,21	626,03	0,15	2,44	0,00	196,00	171,00	109,00	8,39	9,08	13,12	18,62	24,67
01c.JPG	Nó	Cariado	1,00	4.763,94	76,40	108,85	0,70	0,00	0,00	86,00	82,00	55,00	10,46	10,15	32,81	26,83	19,87
01c.JPG	Nó	Cariado	2,00	8.442,36	110,87	144,00	0,77	0,00	0,00	91,00	84,00	55,00	10,32	10,15	30,72	27,40	20,47
01c.JPG	Nó	Firme	3,00	974,91	38,54	50,03	0,77	0,00	0,00	149,00	125,00	78,00	9,27	9,19	16,66	15,50	12,29
01c.JPG	Nó	Firme	4,00	1.864,35	43,27	72,34	0,60	0,00	0,00	138,00	115,00	66,00	8,96	9,04	18,38	21,57	18,52

Figura 64 – Planilha de resultados dos defeitos encontrados na tábua.

6.7. Classificação das tábuas pelo software

A partir da classificação dos defeitos, a tábua foi classificada, obedecendo aos parâmetros já mencionados, conforme apresenta a Figura 65. O tempo médio de processamento total levou aproximadamente 15 segundos, utilizando-se de um computador com processador Pentium Centrino Duo de 1,66 GHz, com 4 GB de memória RAM e sistema operacional Microsoft Windows Vista 32 bits.

Defeitos		Tábuas									
Nome	Classe	Comprimento	Largura	Diâm. nós Vazados	Diâm. nós Cariados	Largura máx Medula	Comprimento % M...	Diâm. nós Firmes	Diâm. Bolsas de R...	Comprimento Bols...	
01c.JPG	Segunda	2.007,91	244,04	0,00	38,22	97,35	96,63	16,69	0,00	0,00	

Figura 65 – Planilha do resultado da classificação da tábua.

A eficiência do software na classificação das tábuas quanto a nós, medula e bolsa de resinas foi avaliada com uso da tabela de confusão (Tabela 8).

Tabela 8 – Matriz de confusão do comparativo das classificações manuais e pelo software

		Classificação manual					Total	Erro de inclusão (%)
		Terceira classe	Segunda classe	Primeira classe	Classe Extra	Classe Super		
Classificação pelo software	Terceira classe	0					0	0,0
	Segunda classe		24	1			25	0,0
	Primeira classe		2	37			39	5,1
	Classe Extra		1	2	0	1	4	75,0
	Classe Super			1		15	16	6,2
	Total		0	27	41	0	16	84
Erro de omissão (%)		0,0	0,0	2,4	0,0	6,2		9,5

A Tabela 8 ilustra, por exemplo, que para a primeira classe o software classificou 39 tábuas. Delas, 37 correspondiam, de fato, a essa classe, conforme demonstrou a classificação. As duas tábuas que não correspondiam a essa classe - falso-positivos, resultaram num erro de inclusão (ou superestimação) de 5,1% (2 tábuas em 39). Os erros de inclusão atingiram valores elevados na classe extra. Além do erro de classificação do software, o reduzido número de exemplares nessa classe favoreceu a ocorrência de um erro tão elevado. Nos demais casos, os erros encontrados foram pequenos.

Análise semelhante pode ser conduzida para avaliação dos erros de omissão, que detecta os falso-negativos. A análise, conduzida nas colunas da tabela, mostra que das 41 tábuas classificadas manualmente como de primeira classe, o software só se omitiu em 1, levando a um erro de omissão (ou subestimação) de apenas 2,4% (1 tábua em 41).

Numa análise global avalia-se que o software teve um erro de 9,5% ou um acerto de 90,5% (76 tábuas em 84). Kauppinen (1999), em trabalho pioneiro sobre o assunto, utilizando-se de um classificador para seis tipos de defeitos de tábuas de *Pinus*, obteve índice de acerto de 66%. Para a classificação de defeitos na madeira de eucalipto, Khoury et al. (2006), com uso de redes neurais artificiais, dependendo do tamanho de blocos da imagem, obtiveram taxas de exatidão de 83,1% (blocos de 64x64 *pixels*) e 76,6% (32x32 *pixels*). Também estudando madeira de eucalipto, Gomes et al. (2008) tiveram taxa de acerto de 81%.

7. CONCLUSÕES

Estudaram-se neste trabalho técnicas de processamento de imagens digitais para detecção dos principais defeitos na madeira serrada de coníferas de uso geral (não estrutural).

Nenhuma das técnicas estudadas, quando aplicada isoladamente, foi satisfatória na detecção de nós, medula e bolsa de resina. Das combinações estudadas, a que trouxe melhor resultado na detecção geral dos nós foi a segmentação por crescimento de regiões e por limiarização, seguidas da operação binária XOR e das operações morfológicas de abertura e fechamento para eliminação de ruídos.

Para a segmentação das medulas, o método de crescimento de regiões foi indispensável, pois apenas a aplicação do método de segmentação por limiarização não se mostrou efetivo.

Para o reconhecimento e a caracterização dos nós cariados foi aplicado com sucesso o método que utiliza a matriz de co-ocorrência, com análise das características de entropia e contraste.

O software de processamento de imagens digitais, desenvolvido na linguagem Java, agilizou os processos de detecção, classificação dos defeitos (nós, medula e bolsa de resina) e das tábuas, com uma porcentagem de acerto de 90,5%, em um universo de 84 tábuas estudadas.

Na continuidade dessa linha de pesquisa entendem-se como prioritárias as seguintes atividades:

- Implementação das tecnologias de redes neurais e lógica Fuzzy ao software desenvolvido;
- processamento de imagens em *frames* sucessivos;
- desenvolvimento de um equipamento de automação industrial para classificação de madeira serrada.

8. REFERÊNCIAS

AMERICAM SOCIETY OF TESTING AND MATERIALS. **ASTM D 143**. West Conshohocken, 1982. 31 p.

AMERICAM SOCIETY OF TESTING AND MATERIALS. **ASTM D 245-93**: Standard practice for establishing structural grades and related allowable properties for visually graded lumber. West Conshohocken, 1998. 34p.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 11.700 (CB-205)**: madeira serrada de coníferas provenientes de reflorestamento para uso geral. Rio de Janeiro, 1991. 6 p.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 12.297 (NB-1381)**: madeira serrada de coníferas provenientes de reflorestamento, para uso geral: medição e quantificação de defeitos. Rio de Janeiro, 1991. 6 p.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 12.498 (PB-1560)**: madeira serrada de coníferas provenientes de reflorestamento, para uso geral: dimensões e lotes. Rio de Janeiro, 1991. 6 p.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 12.551**: madeira serrada: terminologia. Rio de Janeiro, 2002. 10 p.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 7190**: projeto de estrutura de madeira. Rio de Janeiro, 1997. 3 p.

ASSOCIAÇÃO BRASILEIRA DE PRODUTORES DE FLORESTAS PLANTADAS. **Anuário estatístico da ABRAF 2009**: ano base 2008. Brasília, DF, 2009. 120 p.

ASSOCIAÇÃO BRASILEIRA DE PRODUTORES DE MADEIRAS. **Pinus**: catálogo de normas de madeira serrada. Curitiba, 2001. 34 p.

BARALDI, A.; PARMIGGIANI, F. A investigation of the textual characteristics associated with gray level cooccurrence matrix statistical parameters. *IEEE Transactions on Geoscience and Remote Sensing*, New York. v. 33, n. 2, p. 293-304, 1995.

BURGER, L. M.; RICHTER, H. G. **Anatomia da madeira**. São Paulo: Nobel, 1991. 154 p.

CHOW, C. K; KANEKO, T. Automatic detection of the left ventricle from cineangiograms. **Computers and Biomedical Research**, New York, v. 5, p. 388-410, 1972.

CRANE, R. **A simplified approach to image processing**. Upper Saddle River: Prentice-Hall, 1997. 317p.

CRUZ, E. S. et al. Comparação de classificadores de imagens digitais na determinação da cobertura do solo. **Engenharia Agrícola**, Viçosa, v. 28, n. 2, p. 237-244, 2008.

DENADAI, M. **Comunicação pessoal** [jan. 2010]. Entrevistador: Ricardo Rall

DOYLE, W. Operations useful for similarity invariant pattern recognition. **Journal of ACM**, New York, p. 259-267, 1962.

DRUMMOND, I. N. **Implementação do método de classificação contínua fuzzy k-médias no ambiente TerraLib**. 2003. 35p. Monografia (Curso de Introdução ao Geoprocessamento)-Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2003. Disponível em: <<http://www.dpi.inpe.br/cursos/ser300/Trabalhos/isabela.pdf>>. Acesso em: 29 ago. 2008.

FONSECA, F. H. Tendências e perspectivas para o setor de florestas plantadas. **Revista Opiniões**, Ribeirão Preto, n. 13, p. 1-3, 2008.

GOMES, J. G. et al. Desenvolvimento e avaliação de um protótipo classificador de tábuas usando técnicas de visão artificial. **Revista Árvore**, Viçosa, v. 32, n. 5, p. 949-959, 2008.

GOMES, J.; VELHO, L. **Computação gráfica**. Rio de Janeiro: Instituto de Matemática Pura e Aplicada, 1998. v. 1.

GONÇALVES, E. **Dominando Netbeans**. São Paulo: Ciência Moderna, 2006. 326 p.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. São Paulo: Edgard Blucher, 2000. 509 p.

GONZALEZ, R.C.; WOODS, R.E. **Digital Image Processing using Matlab**. Pearson Education Inc. Upper Saddle River, New Jersey. 2004. p.337 – 358.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural Features for Image Classification. **IEEE Transactions on Systems: man and cybernetics**, v. 3, n.6, New York, p. 610-621, 1973.

HARALICK, R. M.; SHAPIRO, L. G. **Computer and robot vision**. Reading: Addison-Wesley, 1992. v. 1.

HAYGREEN, J. G.; BOWYER, J. L. **Forest productions and wood science: an introduction**. 3rd ed. Ames: Iowa State University Press, 1995. 500 p.

HERNANDEZ, F. P.; SHIMABUKURO, Y. E. **Estabelecimento de metodologia para avaliação de povoamentos florestais artificiais, utilizando-se dados do Landsat**. São José dos Campos: INPE, 1978. 169 p. (INPE 1271- TPT- 098).

KAUPPINEN, H. **Development of a color machine vision method for wood surface inspection**. 1999. 133f. Dissertation (Master in Electrical of Engineering)-University of Oulu, Oulu, 1999.

KHOURY Jr., J.K.; PINTO, F.A.C.; QUIEROZ, D.N.; DELLA LUCIA, R.M.; RESENDE, R.C. Redes neurais para reconhecimento de defeitos de madeira serrada de eucalipto em imagens digitais. **Scientia Florestalis**, Piracicaba, n. 70, p. 85-96, 2006.

KLINE, D.E.; SURAK, C.; ARAMAN, P.A. Automated hardwood lumber drading utilizing a multiple sensor machine vision technology. **Computers and Electronics in Agriculture**, Maryland Heights, n.41, p. 139-155, 2003.

KOIVO, A. J.; KIM, C. W. Automatic classification of surface defects on red oak boards. **Forest Products Journal**, Madison, v. 39, n. 9, p. 22-30, 1989.

KRONKA, F. J. N.; BERTOLANI, F.; PONCE, R. H. **A cultura do Pinus no Brasil**. São Paulo. Páginas e Letras, 2005. 156 p.

LEE, S.; ABBOTT, A. L.; SCHMOLDT, D. L. Surface shape analysis of rough lumber for wane detection. **Computers and Electronics in Agriculture**, New York, n. 41, n. 1/3, p. 121-137, 2003.

LLOYD, D. E. **Automatic target classification using moment invariants of image shapes**. Farnborough, 1985. 231p. (Technical reports RAE IDN AW126).

MANSON, D. et al. Measurement of C bands in human chromosomes. **Computers in Biology and Medicine**, Elmsford, v. 5, n. 3, p. 179-201, 1975.

NEWMAN, T. S.; JAIN A. K. A survey of automated visual inspection. **Computer Vision and Image Understanding**, Orlando, n. 61, p. 231-262, 1995.

NIBLACK, W. An introduction to image processing. Englewood Cliffs: Prentice Hall, 1986. 410 p.

NOCK, R.; NIELSEN, F.: Statistical Region Merging. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. IEEE CS press. (26)-11, 2004, p. 1452-1458.

OLIVEIRA, L. E. S. et al. Inspeção automática de defeitos em madeiras de Pinus usando visão computacional. **Revista de Informática Teórica e Aplicada**, Porto Alegre, v. 25, n. 2, p. 203-217, 2008.

OTSU, N. A threshold selection method from gray level histograms. **IEEE Transactions on Systems: man and cybernetics**, New York, v. 9, n. 1, p. 62-66, 1979.

PANSHIN, A. J.; ZEEUW, C. de. **Textbook of wood technology**. 4th ed. New York: McGraw-Hill, 1980. 722 p.

PEDRINI, H.; SCHWARTZ, W.R. Análise de imagens digitais. São Paulo: Thomson Learning, 2008. 508 p.

PRATES, L. G.; FERNANDES, J. M. C. Avaliando a taxa de expansão de lesões de *Bipolaris sorokiniana* em trigo. **Fitopatologia Brasileira**, Brasília, v. 26, p. 185-191, 2001.

PUN, T. A new method for gray-level pictures threshold using the entropy of the histogram. **Signal Processing**, Stockholm, v. 2, n. 3, p. 223-237, 1980.

QUOIRIN, N. S. R. **Diagnóstico de defeitos em madeira por tomografia de raios- X**. 2004. 142 f. Dissertação (Mestrado em Engenharia de Materiais e Processos)-Universidade Federal do Paraná, Paraná, 2004.

RALL, R.; BALLARIN, A. W. Influência das características dos anéis de crescimento na densidade, resistência e rigidez da madeira de *Pinus taeda* L. **Energia na Agricultura**, Botucatu, v. 22, n. 2, p. 81-93, 2007.

RICHTER, H. G.; BURGER, L. M. **Anatomia da madeira**. 2. ed. Curitiba: UFPR, Setor de Ciências Agrárias, Departamento de Engenharia e Tecnologias Rurais, 1978. 76 p.

RIDLER, T. W.; CALVARD, S. Picture thresholding using an interative selection method. **IEEE Transactions on Systems: man, and cybernetics**, New York, v. 8, p. 630-632, 1978.

RODENACKER, K.; BENGTTSSON, E. A feature set for cytometry on digitizedmicroscopic images. **Analytical Cellular Pathology**, Amsterdam, v. 25, p. 1-36, 2003.

ROSENFELD, A.; KAK, A. C. **Digital picture processing**. Orlando: Academic Press, 1982. v. 1 e 2.

SAUVOLA, J.; PIETAKSINEN, M. Adaptive document image binarization. **Pattern Recognition**, Montreal, v. 33, p. 225-236, 2000.

SENA JUNIOR, D. G.; PINTO, F. A. C.; QUEIROZ, D. M. Algorithm for classification of fall armyworm (*Spodoptera frugiperda*, Smith) damaged corn plants on digital images. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 5, n. 3, p. 502-509, 2001.

SHAPIRO, L. G.; STOCKMAN, G. C. Computer vision. New Jersey: Prentice-Hall, 2001. 410 p.

SHIMOYAMA, V. R.; BARRICHELO, L. E. G. Influência de características anatômicas e químicas sobre a densidade básica da madeira de *Eucalyptus* spp. In: CONGRESSO ANUAL DE CELULOSE E PAPEL, 24., São Paulo, 1991. **Anais...** São Paulo: ABTCP, 1991. p. 91-100.

SIMÕES, A. S.; COSTA, A. H. R. Classificação de laranjas baseadas em padrões visuais. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 6, 2003, Bauru. **Anais...** Bauru: Sociedade Brasileira de Automática, 2003. p. 77-81.

SIMÕES, J. W. et al. **Formação, manejo e exploração de florestas com espécies de rápido crescimento**. Brasília, DF: IBDF, 1981. 131 p.

SPÓSITO M. B. **Dinâmica temporal e espacial da mancha preta (*Guignardia citricarpa*) e quantificação dos danos causados à cultura dos citros**. 2003. 112 f. Tese (Doutorado em Agronomia)-Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2003.

STANALKER, J. J.; HARRIS, E. C. **Structural design in wood**. New York: Chapman and Hall, 1989. 426 p.

TEIXEIRA, E. F.; CICERO, S. M.; NETO, D. D. Análise de imagens digitais na avaliação de plântulas de milho. **Revista Brasileira de Sementes**, Pelotas, v. 28, n. 2, p. 159-167, 2006.

TRIGO, T. **Equipamento fotográfico: teoria e prática**. São Paulo: Editora Senac, 2005. 260p.
USDA FOREST SERVICE. *Pinus taeda*. Disponível em: <http://www2.fpl.fs.fed.us/TechSheets/softwoodna/htmldocs/pinustaeda.html>. Acesso em: 12 nov. 2004.

WEZKA, J. S.; NAGEL, R. N.; ROSENFELD, A. A threshold selection technique. **IEEE Transactions on Computer**, Los Alamitos, v. 12, p. 1322-1326, 1974.

YASUDA, Y.; DUBOIS, M.; HUANG, T. S. Data compression for check Processing Machine. **Proceedings of IEEE**, New York, v.7, n. 68, p. 874-885, 1980.

ZABOT, L. et al. Uso de imagens digitais para avaliação de plântulas de feijão. **Revista Brasileira de Sementes**, Pelotas, v. 30, n. 2, p. 184-192, 2008.

APÊNDICE

Resultados da classificação manual das tábuas e comparativo com o software

Relação de amostras, mensuração e classificação, segundo Norma ABNT 11.700

Num.	Ref. tábuas	Compr.	Largura (mm)	Diâmetro do Nó (mm)						Bolsa de resina		Medula		Classificação Manual	Classificação Software			
				Firme	nº	Cariado	nº	Gravata	nº	Vazado	nº	Grupo	Largura (mm)			Comprim. (mm)	Largura (mm)(1)	Comprim. (mm)
1*	5/2 E1	2004	243	40	3			105	1				125	2004				
								110	2									
			Totais	40		0		215		0		0	0	125	2004			
			%	8		0		44		0		0	0	125	100	Segunda	Segunda	
2	1/3 E1	2004	290	17	1													
				47	2													
				80	3													
				144	4													
				37	5													
				34	6													
				81	7													
			Totais	440		0		0		0		0	0	0	0			
			%	76		0		0		0		0	0	0	0	Primeira	Primeira	
3*	6/2 E2	2004	242	30	3	21	1											
				7	4	51	2											
				10	5	42	6											
				14	7	40	8											
			Totais	61		154		0		0		0	0	0	0			
			%	13		32		0		0		0	0	0	0	Segunda	Primeira	
4	5/1 D3	2004	195							40	1							
										14	2							
			Totais	0		0		0		54		0	0	0	0	0		
			%	0		0		0		14		0	0	0	0	0	Segunda	Segunda
5	1/3 D1	2004	290			86	1											
						6	2											
						47	3											
						77	4											
						22	5											
						88	6											
						21	7											
						24	8											
			Totais	0	0	371	36	0	0	0	0	0	0	0	0	0		
			%	0	0	64		0	0	0	0	0	0	0	0	0	Segunda	Segunda
6	3/1 E1	2004	241	2	3	27	1											
				23	5	37	2											
				22	6	25	4											
				20	7	28	9											
				7	8	36	10											
						26	11											
			Totais	75		180		0	0	0	0	0	0	0	0	0		
			%	15		37		0	0	0	0	0	0	0	0	0	Segunda	Primeira
7*	1/2 D2	2005	289	62	2	55	1											
				49	3	72	5											
				7	4	85	6											
				72	7													
				47	8													
			Totais	237		212		0	0	0	0	0	0	0	0	0		
			%	41		37		0	0	0	0	0	0	0	0	0	Segunda	Segunda
8*	5/1 E2	2004	241	48	4	33	1			85	3			58	135			
				36		33	2											
			Totais	84		66		0		85		0	0	0	58	135		
			%	17		14		0		18		0	0	0	58	7	Segunda	Segunda
9	4/1 E1	2004	248	56	1									52	1750			
				25	2													
				17	3													
				29	4													
			Totais	127		0		0	0	0	0	0	0	0	52	1750		
			%	25		0		0	0	0	0	0	0	0	52	88	Primeira	Primeira
10	1/1 E4	2004	240	64	2	38	1			45	4							
						106	3											
			Totais	64		144		0		45		0	0	0	0	0	0	
			%	13		30		0		9		0	0	0	0	0	Primeira	Segunda
11	3/1 D1	2004	241	8	1	13	3			49	2							
				31	4	34	6											
				33	5	34	7											
				40	9	30	8											
			Totais	112		111		49		0		0	0	0	0	0	0	
			%	23		23		10		0		0	0	0	0	0	Primeira	Primeira
12	6/1 D1	2004	242	35	1	27	4											
				34	2	54	6											
				69	3	42	7											
				19	5	63	8											
						50	9											
			Totais	156		209		0	0	0	0	0	0	0	0	0	0	
			%	32		43		0	0	0	0	0	0	0	0	0	Segunda	Segunda
13	2/3 D1	2004	245	7	2	16	1											
			Totais	7		16		0	0	0	0	0	0	0	0	0	0	
			%	1		3		0	0	0	0	0	0	0	0	0	Primeira	Primeira

Num.	Ref. tábu	Compr.	Largura (mm)	Diâmetro do Nó (mm)						Bolsa de resina		Medula		Classificação Manual	Classificação Software		
				Firme	nº	Cariado	nº	Gravata	nº	Vazado	nº	Grupo	Largura (mm)			Comprim. (mm)	Largura (mm)(1)
14*	1/2 E1	2004	297	18	2	80	1					76	320				
				32	4	123	3					85	1600				
				10	5	95	6										
				40	7												
			Totais	100		298		0	0	0	0	0	161	1920			
			%	17		50		0	0	0	0	0	161	96	Segunda	Segunda	
15	5/2 D1	2004	244	57	1												
				Totais			57		0	0	0	0	0	0	0		
				%	0		12		0	0	0	0	0	0	0	0	Primeira
16*	5/3 E1	2004	243	48	1						2	15	59	1260			
				40	2						4	37					
				7	3												
				Totais	95		0		0	0	0	6	52	59	1260		
			%	20		0		0	0	2	3	59	63	Primeira	Primeira		
17	4/3 E1	2004	243	33	1												
				56	2												
				48	3												
				Totais	136		0		0	0	0	0	0	0	0	0	
			%	28		0		0	0	0	0	0	0	0	Super	Extra	
18*	5/2 E2	2004	242	50	3	70	1						47	260			
				50	5	40	2						60	175			
				90	4												
				Totais	100		200		0	0	0	0	0	0	107	175	
			%	21		41		0	0	0	0	107	9	Segunda	Segunda		
19*	2/3 E1	2003	244	30	1	26	5				9	45					
				52	2												
				27	3												
				13	4												
			Totais	122		26		0	0	0	9	45	0	0			
			%	25		5		0	0	0	4	2	0	0	Primeira	Primeira	
20	3/2 E1	2004	245	55	1												
				35	2												
				52	3												
				Totais	142		0		0	0	0	0	0	0	0	0	
			%	29		0		0	0	0	0	0	0	0	Super	Super	
21	4/4 E1	2004	170	7	1	28	5										
				9	2												
				8	3												
				20	4												
			Totais	45		28		0	0	0	0	0	0	0			
			%	13		8		0	0	0	0	0	0	0	Primeira	Extra	
22	3/3 E1	2004	193	15	1												
				13	2												
				13	3												
				12	4												
			Totais	66		0		0	0	0	0	0	0	0			
			%	17		0		0	0	0	0	0	0	0	Super	Super	
23*	2/2 D1	2004	244	50	1												
				46	2												
				26	3												
				Totais	122		0		0	0	0	0	0	0	0	0	
			%	25		0		0	0	0	0	0	0	0	Super	Super	
24	5/4 E1	2004	195	17	1												
				49	2												
				29	3												
				38	4												
			Totais	133		0		0	0	0	0	0	0	0			
			%	34		0		0	0	0	0	0	0	0	Super	Super	
25	1/3 D2	2004	243	44	2	20	1										
				55	3	86	4										
				6	5												
				10	6												
			Totais	115		106		0	0	0	0	0	0	0			
			%	24		22		0	0	0	0	0	0	0	Primeira	Primeira	
26*	3/1 E2	2004	240	26	2	37	1										
				25	5	29	3										
				25	6	12	4										
				26	7	27	8										
				30	9												
				24	10												
			Totais	102		159		0	0	0	0	0	0	0			
			%	21		33		0	0	0	0	0	0	0	Segunda	Segunda	
27*	1/1 E1	2004	304	28	1	105	2						125	2004			
				10	5	30	3										
				24	8	56	6										
				47	10	50	7										
				62	11	26	9										
				Totais	171		267		0	130		0	0	0	0	125	2004

Num.	Ref. tábu	Compr.	Largura (mm)	Diâmetro do Nó (mm)						Bolsa de resina		Medula		Classificação Manual	Classificação Software
				Firme	nº	Cariado	nº	Gravata	nº	Vazado	nº	Grupo	Largura (mm)		
			%	28	44	0	21	0	0	0	0	125	100	Segunda	Segunda
28*	5/1 D1	2005	291	33	2	50	1					83	950		
				15	4	44	3					70	210		
				30	7	55	5								
				30	8	80	6								
			Totais	108		229		0	0	0	0	153	1160		
			%	19		39		0	0	0	0	153	58	Segunda	Segunda
29*	6/1 E1	2004	290	15	1	32	4								
				12	2	27	5								
				48	3	52	7								
				18	6	25	9								
				7	8										
			Totais	100		136		0	0	0	0	0	0		
			%	17		23		0	0	0	0	0	0	Primeira	Primeira
30	1/1 D2	2004	290			44	1								
						66	2								
						40	3								
						46	4								
						48	5								
						45	6								
			Totais	0		289		0	0	0	0	0	0		
			%	0		50		0	0	0	0	0	0	Segunda	Segunda
31	4/2 E1	2004	242	9	2					229	1				
				7	3										
			Totais	15		0		0	0	229	1	0	0		
			%	3		0		0	0	47	0	0	0	Super	Super
32*	6/3 E3	2003	138	14	1						1	55			
				43	2										
				46	3										
				14	4										
			Totais	117		0		0	0	0	1	55	0		
			%	42		0		0	0	0	1	3	0	Super	Super
33	5/1 D2	2004	240	31	2	51	1								
						28	3								
			Totais	31		79		0	0	0	0	0	0		
			%	6		16		0	0	0	0	0	0	Primeira	Primeira
34	2/2 D2	2004	196	54	1										
				47	2										
			Totais	27,51		0		0	0	0	0	0	0		
			%	#REF!		0		0	0	0	0	0	0	Super	Super
35*	2/1 E3	2004	168			44	1			33	2				
			Totais	0		44		0	33	0	0	0	0		
			%	0		13		0	10	0	0	0	0	Primeira	Primeira
36*	6/2 D1	2005	194	13	1	20	3			44	5				
				30	2	65	4								
				55	6	43	7								
				4	8										
			Totais	102		128		0	44	0	0	0	0		
			%	26		33		0	11	0	0	0	0	Segunda	Segunda
37	6/2 E3	2004	195	14	2	44	1								
				48	3	34	5								
				10	4	19	6								
				57	7										
			Totais	128		97		0	0	0	0	0	0		
			%	33		25		0	0	0	0	0	0	Primeira	Primeira
38	1/2 E2	2004	192	5	1	53	4								
				58	2										
				5	3										
			Totais	69		53		0	0	0	0	0	0		
			%	18		14		0	0	0	0	0	0	Primeira	Primeira
39*	6/3 D1	2005	196	23	1	35	6				10	220			
				27	2	4	8								
				43	3										
				60	4										
				7	5										
				58	7										
			Totais	218		39		0	0	0	10	220	0		
			%	55		10		0	0	5	11	0	0	Primeira	Extra
40	1/1 D1	2004	326			59	1								
						46	2								
						43	3								
						39	4								
						74	5								
						39	6								
			Totais	0		300		0	0	0	0	0	0		
			%	0		46		0	0	0	0	0	0	Segunda	Segunda
41	2/1 D4	2004	166	0	0					6	1				
			Totais	0		0		0	6	0	0	0	0		
			%	0		0		0	2	0	0	0	0	Primeira	Primeira

Num.	Ref. tábua	Compr.	Largura (mm)	Diâmetro do Nó (mm)						Bolsa de resina		Medula		Classificação Manual	Classificação Software	
				Firme	nº	Cariado	nº	Gravata	nº	Vazado	nº	Grupo	Largura (mm)			Comprim. (mm)
			Totais	22		95		0		0		0		0		0
			%	4		16		0		0		0		0		0
77*	1/1 E5	2004	192			48	2			69	1					
			Totais	0		73	3			69	1			0		0
			%	0		19	4			18	2			0		0
78*	3/1 D2	2004	193	18	2	40	1			30	7					
			Totais	51		138		0		30		0		0		0
			%	13		36		0		8		0		0		0
79*	1/4 E2	2005	137	27	1	11	2									
			Totais	59		109		0		0		0		0		0
			%	21		40		0		0		0		0		0
80*	5/1 E3	2005	167							40	1		5	55		
			Totais	0		0		0		40		0	5	55		0
			%	0		0		0		12		0	3	3		0
81	3/3 D1	2004	168	19	1	15	3					3	30			
			Totais	39		26		0		0		3	30		0	0
			%	12		8		0		0		2	2		0	0
82	3/2 D2	2004	166	36		17						4	30			
			Totais	36		17		0		0		4	30		0	0
			%	11		5		0		0		2	2		0	0
83*	2/1 E1	2006	291	34	1	132	3					0	0	105	1260	
			Totais	98		132		0		0		0	0	105	1260	
			%	17		23		0		0		0	0	105	63	Primeira
84*	1/1 E2	1959	303	56	1	130	5					0	0	104	660	
			Totais	208		150		0		0		0	0	104	660	
			%	35		25		0		0		0	0	104	33	Primeira