

**UNIVERSIDADE DE CAXIAS DO SUL
ÁREA DO CONHECIMENTO DE CIÊNCIAS EXATAS E ENGENHARIAS**

ALEXANDER AUGUSTO DELLABETHA

**SISTEMA INDUSTRIAL PARA AQUISIÇÃO DE IMAGENS E CLASSIFICAÇÃO DE
NÓS EM MADEIRA SERRADA**

**BENTO GONÇALVES
2018**

ALEXANDER AUGUSTO DELLABETHA

**SISTEMA INDUSTRIAL PARA AQUISIÇÃO DE IMAGENS E CLASSIFICAÇÃO DE
NÓS EM MADEIRA SERRADA**

Trabalho de Conclusão do Curso apresentado no Curso de Engenharia Eletrônica do Campus Universitário da Região dos Vinhedos, da Universidade de Caxias do Sul, como requisito parcial à obtenção do título de Engenheiro Eletrônico.

Orientador: Prof. Dr. Andre Gustavo Adami

**BENTO GONÇALVES
2018**

ALEXANDER AUGUSTO DELLABETHA

**SISTEMA INDUSTRIAL PARA AQUISIÇÃO DE IMAGENS E CLASSIFICAÇÃO DE
NÓS EM MADEIRA SERRADA**

Trabalho de Conclusão do Curso apresentado no Curso de Engenharia Eletrônica do Campus Universitário da Região dos Vinhedos, da Universidade de Caxias do Sul, como requisito parcial à obtenção do título de Engenheiro Eletrônico.

Aprovado em: ____/____/____.

Banca Examinadora

Orientador Prof. Dr. Andre Gustavo Adami
Universidade de Caxias do Sul - RS

Profa. Dra. Marilda Machado Spindola
Universidade de Caxias do Sul - RS

Prof. Me. Rodrigo Tregnago
Universidade de Caxias do Sul - RS

AGRADECIMENTOS

Agradeço aos meus pais e à minha irmã Larissa por todo o incentivo e suporte dedicados a mim durante esta caminhada.

À minha namorada Gabriela pela compreensão e palavras de apoio, durante os momentos difíceis.

Ao Prof. Andre Gustavo Adami por todo o conhecimento agregado, orientações, empenho e paciência para que o trabalho fosse finalizado da melhor forma possível.

Ao Prof. Guilherme Holsbach Costa pelo suporte e disponibilização do material necessário para o desenvolvimento do projeto.

RESUMO

Tendo como motivação a relevância econômica gerada pelo mercado florestal brasileiro, bem como o melhor aproveitamento da matéria prima e maior eficiência no processo de manufatura de indústrias madeireiras, principalmente de pequeno porte, propõe-se um modelo teórico de sistema de baixo custo para localização e classificação de nós em madeira serrada. As classes compreendem nós do tipo sadio, morto e podre, que apresentam características visuais e estruturais diferentes. As imagens de nós são adquiridas por câmera CCD, armazenadas em uma base de dados e rotuladas manualmente, visando à determinação de sua localização e seu tipo. Primeiramente, o sistema segmenta as imagens a fim de isolar as regiões afetadas por nós e em seguida os classifica. Dois métodos de segmentação foram avaliados: filtros Gabor e por reconstrução morfológica. Após a detecção dos nós, o sistema extrai as características para classificação do nó. As características são extraídas a partir de cores das três camadas do RGB, texturas, por LBP, GLCM e filtros Gabor. Como a extração de características utilizando filtros de Gabor gera vetores de alta dimensionalidade, o método LDA é aplicado para reduzi-la e também para aumentar a separabilidade das classes e reduzir a variabilidade dentro da classe. Dois classificadores são avaliados: Máquinas de Vetor de Suporte e o Perceptron de Multi Camadas. Uma base de dados com 1000 imagens foi coletada para avaliar o sistema. A detecção dos nós obteve uma acurácia de 94,4. O erro médio de localização foi de aproximadamente 0,9 mm (desvio padrão de 1,5 mm), medidos no ponto central do nó. A classificação obteve uma acurácia de 95,7%, utilizando 707 imagens de nós.

Palavras-chave: Classificação de Nós de Madeira, Segmentação de Nós de Madeira.

ABSTRACT

Based on the economic relevance generated by the Brazilian forest market, as well as the better use of the raw material and greater efficiency in the manufacturing process of wood industries, especially small ones, a theoretical model of low cost system for localization and classification of knots in lumber. The classes comprise knots of the sound, dead and rotten type, which have different visual and structural characteristics. The images of knots are acquired by CCD camera, stored in a database and labeled manually, in order to determine their location and type. The system first segments the images in order to isolate the regions affected by knots and then classifies them. Two methods of segmentation were evaluated: Gabor filters and morphological reconstruction. After knot detection, the system extracts the characteristics for knot classification. Features are drawn from three layers RGB colors, textures, by LBP, GLCM and Gabor filters. As the extraction of characteristics using Gabor filters generates vectors of high dimensionality, the LDA method is applied to reduce it and also to increase the separability of the classes and to reduce the variability within the class. Two classifiers are evaluated: Support Vector Machines and Multi-layer Perceptron. A database with 1000 images was collected to evaluate the system. The detection of the knots obtained an accuracy of 94.4. The mean location error was approximately 0.9 mm (standard deviation of 1.5 mm), measured at the center point of the knot. The classification obtained an accuracy of 95.7%, using 707 images of knots.

Keywords: Classification of Wood Knots, Segmentation of Wood Knots.

SUMÁRIO

1	INTRODUÇÃO	9
1.1	OBJETIVO GERAL.....	10
1.2	OBJETIVOS ESPECÍFICOS	10
1.3	ESCOPO E RESTRIÇÕES.....	11
1.4	APRESENTAÇÃO DO TRABALHO.....	11
2	DETECÇÃO DE DEFEITOS EM MADEIRA NA MANUFATURA.....	12
2.1	DEFEITOS DE MADEIRA.....	12
2.2	PADRONIZAÇÃO DA MADEIRA.....	14
2.3	AVALIAÇÃO HUMANA NA INSPEÇÃO DA MADEIRA	15
2.4	SENSORES UTILIZADOS PARA CLASSIFICAÇÃO DE NÓS.....	15
2.4.1	Sensores dielétricos	16
2.4.2	Câmera Térmica Infravermelha	17
2.4.3	Radar de penetração no solo	17
2.4.4	Micro-ondas	18
2.4.5	LASER	19
2.4.6	Raio X	21
2.4.6.1	Inspeção por raio X de passagem única	21
2.4.6.2	Tomografia Computadorizada	22
2.4.7	Sensores de Ondas de Tensão	23
2.4.8	Ultrassom.....	24
2.4.9	Câmera	25
2.5	SISTEMAS BASEADOS EM CÂMERA.....	27
2.5.1	Extração de características	28
2.5.2	Classificadores de nós	33
2.5.2.1	Multilayer Perceptron.....	34
2.5.2.2	Self-Organizing Maps	37
2.5.2.3	Máquinas de vetor de suporte	39
3	IMPLEMENTAÇÃO DO SISTEMA DE DETECÇÃO DE NÓS.....	42
3.1	ARQUITETURA DO SISTEMA	42

3.2	BASE DE DADOS.....	44
3.3	SEGMENTAÇÃO.....	46
3.3.1	Método por filtros Gabor	46
3.3.2	Método de reconstrução morfológica	48
3.4	EXTRAÇÃO DE CARACTERÍSTICAS.....	51
3.5	CLASSIFICAÇÃO.....	53
3.6	MÉTODO DE AVALIAÇÃO.....	54
3.7	RESULTADOS	57
3.7.1	Resultados da detecção de nós	57
3.7.2	Resultados na localização do nó	61
3.7.3	Resultados obtidos na classificação.....	63
4	CONCLUSÕES	68
	REFERÊNCIAS.....	70
	APÊNDICE A – CÓDIGO-FONTE DA ETAPA DE PRÉ-PROCESSAMENTO.....	75

1 INTRODUÇÃO

Segundo Bacha (2017), a cadeia produtiva florestal brasileira, a qual inclui, dentre outros produtos, a manufatura de processados como chapas de madeira ou painéis, constitui um importante papel na economia do país. Em 2015, a mesma gerou um PIB (Produto Interno Bruto) de R\$ 69,1 bilhões, equivalente a 1,15% do PIB brasileiro do mesmo ano. Sendo assim, melhorias no processo de fabricação destes produtos podem ter impacto econômico relevante até mesmo em âmbito nacional.

A produção de madeira serrada em tábuas, utilizadas para inúmeras aplicações, desde esquadrias até cepas de escovas higienizadoras, em muitos casos, exige que o material esteja livre de defeitos denominados como “nós”. Isto porque estes diminuem as propriedades mecânicas, tais como rigidez e elasticidade, além de serem vistos como uma característica visual indesejável. As tábuas de madeira com poucos nós e rachaduras possuem um valor de mercado maior do que placas com um grande número de nós (Hittaweia, et al., 2015).

Atualmente, grande parte das empresas de pequeno porte executam esta classificação, entre a madeira adequada para a utilização e a inadequada, de forma manual, através do trabalho executado por ser humano. As inspeções visuais realizadas por humanos raramente atingem mais de 70% de acurácia para este tipo de classificação. Isso se deve, em grande parte pela fadiga ocular gerada pela tarefa (Huber; McMillin; McKinney, 1985; Pölzleitner; Schwingshagl, 1992; Grönlund, 1995). Além disso, para Hu, Tanaka e Ohtani (2004), a detecção de defeitos realizada por um trabalhador humano, mesmo que qualificado, é insatisfatória por conta do julgamento subjetivo.

Técnicas de visão de máquina vêm sendo utilizadas na indústria para inspeção automática de madeira em fábricas, para aumentar a eficiência no reconhecimento de nós, e até mesmo ultrapassar o desempenho de inspetores humanos (Gu; Andersson; Vicen, 2010). No entanto, para que um sistema automático seja industrialmente útil, é necessário também que ele processe madeira pelo menos tão rápido quanto um trabalhador qualificado. Isso significa que o sistema de visão deve ser capaz de processar uma imagem e fazer a classificação a uma taxa de pelo menos 0,6 metros lineares por segundo. Por último, uma vez que a classificação depende da detecção

de pequenos defeitos de classificação, o sistema de visão deve ser capaz de processar dados de imagem de alta resolução espacial (Connors, et al., 1992).

Para que um sistema de classificação seja realmente robusto, ele deve ser capaz de lidar com uma variedade de diferentes espécies de madeira, mesmo que estas variem significativamente em sua aparência. Os defeitos de classificação também se manifestam de muitas maneiras diferentes (Connors, et al., 1992). Isto faz com que as técnicas de visão de máquina envolvam um conjunto complexo de elementos que exigem modificações para cada aplicação. Uma vez que as imagens tenham sido adquiridas, existem muitas técnicas que podem ser usadas para detectar e classificar as características mais adequadas. No entanto, cada aplicação de produtos de madeira apresenta um conjunto único de requisitos e restrições (Funk, et al., 2003). As limitações mais desafiadoras deste procedimento são o tecido natural, diferentes cores e texturas complicadas das superfícies de madeira (Ünsalan; Erçil, 1998).

Em suma, apesar da quantidade considerável de trabalhos que tenham sido desenvolvidos neste campo, a detecção automática de defeitos de madeira ainda permanece sem uma solução genérica (Connors, et al., 1983) e, portanto, cada nova aplicação exige um novo desenvolvimento. Desta forma, este trabalho propõe a implementação de um sistema para aquisição de imagens e classificação de nós de madeira serrada, para um caso específico de manufatura de uma empresa local.

1.1 OBJETIVO GERAL

Este trabalho tem como objetivo principal o desenvolvimento de um sistema de visão industrial para a aquisição e processamento de imagens e classificação de nós em tábuas de madeira serrada. O mesmo será constituído por câmera, iluminação auxiliar, além de computador pessoal e algoritmo adequado à solução do problema.

1.2 OBJETIVOS ESPECÍFICOS

Visando ao objetivo geral, busca-se o cumprimento dos seguintes objetivos específicos:

- a) Definir o modelo de câmera e formato de imagem adequados para a aplicação;

- b) Construir uma base de dados com imagens de madeira serrada a partir de amostras reais;
- c) Desenvolver um algoritmo para processamento das imagens e redução da quantidade de características a serem classificadas;
- d) Desenvolver um classificador que busque maior acurácia e eficiência possíveis para a localização de nós referente ao grupo de amostras disponibilizado.

1.3 ESCOPO E RESTRIÇÕES

As seguintes restrições são aplicadas ao presente trabalho com a finalidade de restrição aos objetivos geral e específicos:

- a) O classificador a ser desenvolvido se restringirá a sua aplicação na base de dados construída;
- b) O sistema a ser desenvolvido não será implementado em tempo real, visto que a classificação será executada posteriormente à aquisição de todas as imagens da base de dados a ser criada.

1.4 APRESENTAÇÃO DO TRABALHO

Este trabalho é composto por quatro capítulos. No Capítulo 2, são apresentadas as principais classes de nós existentes em tábuas de madeira, bem como o estado da arte para a classificação destes, evidenciando os diferentes tipos de sensores, características e classificadores utilizados para a execução de tal tarefa. O Capítulo 3 aborda a metodologia implementada para o desenvolvimento do projeto com a descrição de cada etapa a ser cumprida, juntamente com suas justificativas, e os resultados obtidos em cada etapa. Por fim, no Capítulo 4 são apresentados algumas considerações finais e perspectivas futuras.

2 DETECÇÃO DE DEFEITOS EM MADEIRA NA MANUFATURA

O reconhecimento dos defeitos de madeira faz-se necessário na indústria florestal madeireira, uma vez que a otimização da utilização da matéria-prima através de sua padronização constitui importante papel econômico. Além de garantir que não haja incidência de defeitos em produtos onde os mesmos sejam prejudiciais, a classificação da qualidade da madeira também pode contribuir para que classes diferentes de madeiras, categorizadas de acordo com suas anormalidades, sejam utilizadas em aplicações diferentes, evitando desperdícios.

Devido aos custos envolvidos, muitas empresas, principalmente de pequeno porte, ainda empregam mão-de-obra humana para a inspeção de toras e tábuas de madeira. Isso geralmente ocasiona prejuízos, devido a falhas na classificação de natureza subjetiva (depende do profissional), inconsistência nas classificações e a velocidade de inspeção, que tem que ser limitada.

Desta forma, diversos trabalhos sobre classificação de defeitos na madeira vêm sendo desenvolvidos nos últimos anos com a utilização de sensores dielétricos, câmeras infravermelhas térmicas, raio x, além de outros.

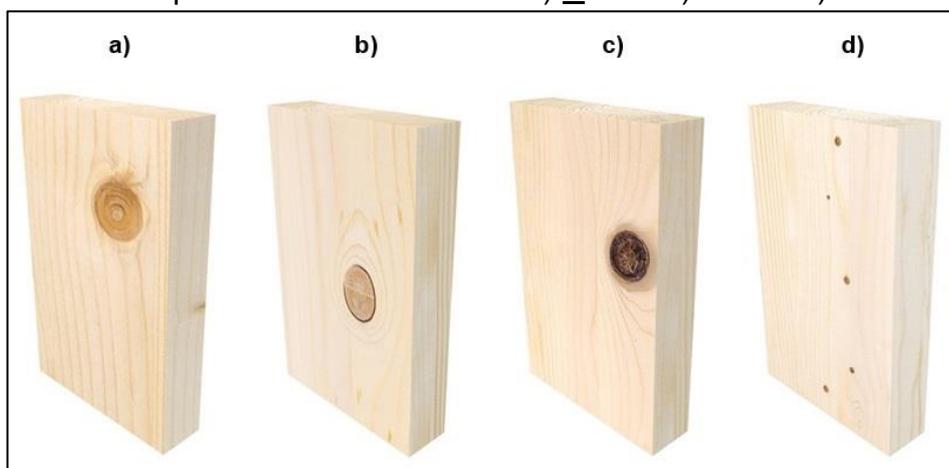
2.1 DEFEITOS DE MADEIRA

Para Connors et al. (1983), um defeito é qualquer característica que torna a madeira inadequada para uma determinada utilização e pode ser enquadrado em duas classes: defeitos biológicos (como nós e bolsas de resina) e defeitos ocorridos durante a manufatura. Os defeitos mais relevantes a serem classificados são os biológicos denominados como nós. Isso porque a árvore precisa deles para poder crescer e, em geral, constituem um papel fundamental para as funções vitais da planta. Por isso, mesmo que haja muitas causas de variações durante o crescimento das árvores, como genética, hábito da planta, condições ambientais, meteorologia, tratamentos silvícolas, colheita, transporte e armazenamento, os nós estarão frequentemente presentes na madeira, mesmo que em proporções diferentes (Grönlund, 1995).

A madeira pode apresentar diversos tipos de nós: *sound knots* (também chamados de nós vivos), *dead knots*, *decayed/rotten knots* e *pin knots* (Gu; Andersson; Vicen, 2010). A Figura 1 mostra exemplos de imagens típicas para esses

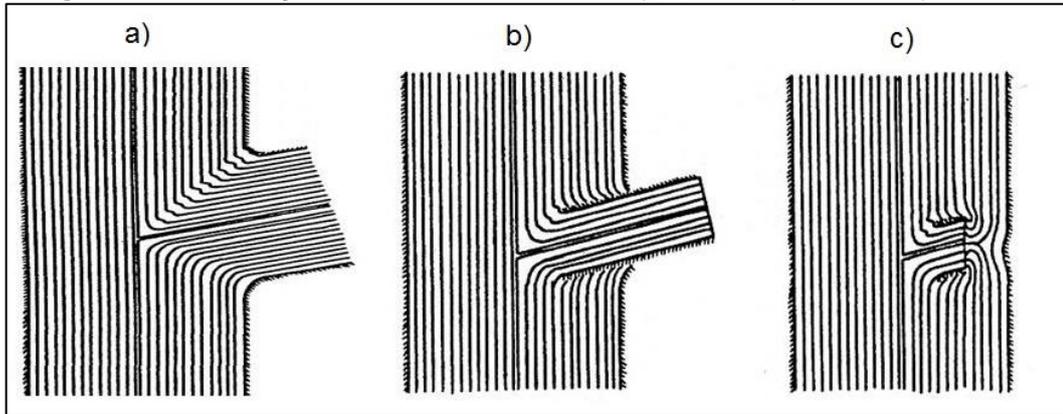
tipos de nós de madeira, que diferem em cor, forma, textura e tamanho. Os nós sadios (*sound*) (Figura 1a) são considerados inofensivos na questão estrutural e são formados por galhos de árvores. Estes nós podem ter algumas curvas em forma circular que remetem à idade dos ramos e possuem cores levemente escuras e diferentes texturas em relação à madeira sem defeitos. Os nós mortos (*deads*) (Figura 1b) são constituídos quando um ramo da árvore deixa de funcionar e geralmente apresentam uma curva de forma circular mais escura em volta de uma área com uma coloração diferente da cor da madeira normal. Pode haver variação para este último, diferenciando-se pela tonalidade escura também em seu interior e recebendo o nome de nó “preto”. Outros tipos de nós existentes são os nós podres (*rotten*) (Figura 1c), também chamado de *decayed*, e os *pins* (Figura 1d). O primeiro é considerado prejudicial porque possui uma densidade menor do que a madeira saudável e pode ter espaços vazios, fazendo com que não seja permitido o seu uso em muitas aplicações. O segundo, por sua vez, é um tipo de nó pequeno com diâmetro máximo de 7 mm, e não constitui depreciação. A formação dos nós pode ser descrita conforme a Figura 2: sendo um nó, a base de um galho, o tipo sadio (Figura 2a) é originado quando a planta é colhida ainda com um galho saudável ou então, em crescimento. O tipo morto (Figura 2b) é gerado com a obstrução ou poda de um galho ocorrida anteriormente ao momento da colheita da árvore. Por fim, o tipo podre (Figura 2c) ocorre quando um galho é obstruído, mas a árvore continua crescendo à sua volta, fazendo com que o mesmo fique na parte interna da planta.

Figura 1 – Exemplos de nós de madeira. a) Sadio. b) Morto. c) Podre. d) Pin.



Fonte: Adaptado de *Swedish wood: Wood grades*. Disponível em: <http://www.swedishwood.com/about_wood/choosing-wood/wood-grades/>. Acesso em: 17 set. 2017.

Figura 2 – Formação de nós de madeira. a) *Sound*. b) *Dead*. c) *Rotten*.



Fonte: Adaptado de *Wood 280 – Macroscopic wood anatomy features*. Disponível em: <http://slideplayer.com/slide/9813330/>. Acesso em: 03 dez. 2017.

2.2 PADRONIZAÇÃO DA MADEIRA

Grönlund (1995) afirma que a ocorrência de imperfeições na madeira deve ser quantificada e classificada. Isto para que se determine a qualidade do material e com isso, faça-se um melhor aproveitamento da matéria-prima. Para tanto, deve-se garantir que o produto final seja utilizado para o propósito mais adequado. Por exemplo, para a produção de esquadrias, podem ser utilizadas placas de madeira que contenham nós vivos e por isso sejam mais baratas. Para alguns tipos de móveis o mesmo material seria inadequado, uma vez que a característica visual não estaria de acordo. Com isso, não se busca somente a homogeneidade através da remoção de defeitos como nós, mas sim o melhor aproveitamento.

A classificação da madeira e sua qualidade constituem um importante papel em principalmente três etapas do processo de produção: durante o manejo de toras, serragem e recorte. Toras com maiores dimensões e formatos mais retilíneos garantem rendimentos maiores e, conseqüentemente, custos mais elevados (Grönlund, 1995). Assim, estas têm de ser agrupadas através de suas características físicas para que o valor correto seja agregado. Durante a serragem do tronco, faz-se uma classificação pelas dimensões e resistência das tábuas já serradas. Neste momento, é possível que haja quebra do material. Então, o controle de qualidade deve garantir que não haja problemas ocasionados por este acontecimento. Por fim, faz-se o recorte. Nesta etapa, o operário humano tem de julgar uma posição de corte, e com base nas propriedades estimadas, como defeitos visuais, avaliar uma nota em cada placa.

Alguns países possuem normas técnicas próprias que regulamentam a classificação deste material e delimitam o preço para cada categoria. A qualidade da placa é definida pelo tamanho e frequência de seus defeitos. Na Áustria, por exemplo, o objetivo da classificação é determinar a qualidade total de uma placa entre três possibilidades: A, B ou C (isto é, bom, médio ou ruim) (Pölzleitner; Schwingshagl, 1992). A qualidade A, por exemplo, corresponde à madeira de borda quadrada, livre de manchas azuis e vermelhas, abatimentos, insetos e poucos nós negros e bolsos de resina. Países como Suécia, EUA e Alemanha também possuem suas regras próprias para classificação e padronização de placas de madeira e toras (Fordaq S.A.). No Brasil, adota-se a ABNT NBR ISO 737:2011, a ABNT NBR ISO 738:2011 e a ABNT NBR ISO 8903:2011 para padronização de madeira serrada de coníferas e folhosas, que são baseadas nas normas internacionais ISO 737:1975, ISO 738:1981 e ISO 8903:1994 (ABNT).

2.3 AVALIAÇÃO HUMANA NA INSPEÇÃO DA MADEIRA

A inspeção de defeitos como nós, baseada em juízos humanos ocasiona muitas decisões incorretas e uma carga mental muito alta para os trabalhadores. Os *graders* geralmente precisam fazer até 30 classificações por minuto. Além disso, uma classificação incorreta tem um impacto relevante na produção (Grönlund, 1995). Na manufatura de painéis perfilados, por exemplo, são utilizadas máquinas de aplainar que fornecem taxas de deslocamento de mais de 200 m/min. Um quadro de 3,3 m de comprimento pode ser aplainado em um segundo. No entanto, se a inspeção da madeira for feita manualmente, a linha de produção deve ser operada abaixo da sua capacidade máxima, porque as classificações não podem ser feitas a esta velocidade (Pölzleitner; Schwingshagl, 1992). Uma taxa de transferência realista, portanto, é de cerca de 100 m/min com trabalhadores humanos. Um dispositivo de classificação automática não só possibilitaria uma produção maior como também melhoraria muito a qualidade do ambiente de trabalho.

2.4 SENSORES UTILIZADOS PARA CLASSIFICAÇÃO DE NÓS

Como será visto a seguir, os sensores mais utilizados para classificação de nós são raio X e câmeras, no entanto, diversos estudos utilizaram outros sensores como:

sensores dielétricos, câmara térmica infravermelha, radar de penetração no solo, micro-ondas, LASER, entre outros.

2.4.1 Sensores dielétricos

Uma forma de detecção de defeitos na madeira é através da varredura das propriedades dielétricas da mesma. Nós e furos alteram as propriedades dielétricas da madeira e a mudança pode ser detectada monitorando o seu sinal de saída. A orientação das fibras da madeira afeta a constante dielétrica. Seu valor é 30% a 60% maior quando tomado paralelamente ao grão do que quando medido perpendicular ao mesmo (Rice; Kumar, 1992). Desta forma, como esta orientação muda significativamente nas proximidades de um nó, faz-se sua identificação.

É possível também fazer o reconhecimento de furos à medida que a madeira se move sob as placas do capacitor. Um buraco causa uma grande queda na constante dielétrica porque esta magnitude, para a madeira é cerca de 100 vezes maior do que para o ar (Rice; Kumar, 1992). A energia armazenada aumenta com umidade e temperatura e decresce à medida que a frequência do campo elétrico aplicado aumenta, por isso, são fatores que devem ser controlados para que as detecções sejam bem-sucedidas. Além disso, as frequências na faixa de Gigahertz são muito sensíveis às pequenas mudanças de umidade dentro da madeira, podendo haver rejeição da madeira sem qualquer defeito, enquanto que em baixas frequências há perda de sensibilidade ao detectar pequenas imperfeições.

Rice e Kumar (1992) e Zhao, Fan e Zheng (2012) propõem sistemas com transdutores em forma de placas planas que atuam como capacitores. O primeiro visa à implementação das placas no mesmo plano e paralelas à superfície da madeira. O campo elétrico emitido por uma placa de capacitor, adentra à madeira e é detectado na mesma face da madeira na outra placa do capacitor. Isto para que seja possível a detecção de defeitos de superfície em diferentes espessuras de madeira e sejam evitados potenciais problemas com detritos que possam cair sobre a placa inferior. O segundo, praticamente desenvolve um capacitor de placas paralelas com permissividade variável, onde o meio dielétrico a ser medido é inserido no interior do mesmo.

2.4.2 Câmera Térmica Infravermelha

Objetos com temperatura superior ao zero absoluto irradiam ondas eletromagnéticas em infravermelho. A tecnologia de imagem térmica infravermelha permite detectar ondas de luz em infravermelho e transformá-las em imagens visíveis. Desta forma, utilizando um sensor de imagens térmicas infravermelho e uma lâmpada infravermelha, Sun, Luo e Wang (2012) descrevem um método para inspeção não destrutivo para toras. Primeiramente, deve-se aquecer a peça a ser verificada através da utilização da lâmpada descrita. Posteriormente, tira-se as fotos e faz-se a análise. Existem dois modelos de detecção: *one-way* e *double-way*. O primeiro significa que o aquecimento e a fotografia em infravermelho da amostra acontecem no mesmo lado da amostra. O segundo, significa que as duas ações acontecem em diferentes lados.

A imagem térmica infravermelha pode detectar furos no meio, falhas e nós, mas são necessárias diferentes condições de teste para detectar diferentes defeitos corretamente. Por exemplo, orifícios existentes no meio das amostras só podem ser detectados por modelo de detecção de duas vias, enquanto as falhas só podem ser detectadas pelo modelo de detecção de sentido único. O tamanho e a posição dos defeitos podem ser determinados de forma mais precisa com maior teor de umidade, embora o tempo de aquecimento da lâmpada infravermelha necessário seja maior (Sun, Luo e Wang, 2012).

2.4.3 Radar de penetração no solo

Defeitos em madeira podem ser detectados por meio da análise das reflexões dos pulsos de ondas de rádio emitidos pelo Radar de penetração no solo (*Ground Penetrating Radar - GPR*) devido as suas propriedades dielétricas. Segundo Halabe, Agrawala e Gopalakrishnan (2009), o GPR emite pulsos de ondas de rádio ou eletromagnéticas do transmissor da antena para a tora a ser investigada. Esses pulsos são refletidos por materiais com diferentes constantes dielétricas. Se o contraste dielétrico entre os dois meios for alto, o coeficiente de reflexão é alto, o que resulta em uma forte reflexão ou sinal de eco. Por outro lado, defeitos como nós e *decays* resultam em reflexões de amplitude mais baixas. Assim, uma análise dos pulsos refletidos permite detectar regiões defeituosas da tora.

Devaru et al. (2005) e Halabe, Agrawala e Gopalakrishnan (2009) apresentam um sistema para classificação de defeitos internos de toras GPR baseado em Radar

de Interface de Sub-superfície (*Subsurface Interface Radar* - SIR). Este sistema possibilita que a coleta e processamento de dados podem ser feitos simultaneamente. O equipamento GPR consiste em um sistema de aquisição de dados e duas antenas de 900 *Megahertz* (MHz). Estas antenas proporcionam profundidades de penetração de até 1 metro, mesmo em toras úmidas. O pós-processamento dos dados adquiridos foi necessário para melhorar os recursos (ecos de sinal) na varredura de dados do radar e reduzir o ruído. Isso ajuda muito a detectar os defeitos de sub-superfície. As etapas básicas envolvidas no pós-processamento foram aferição de ganho de alcance, remoção de fundo e filtragem de ruído. Os sinais de radar são propensos a atenuar com profundidade crescente. Por isso, o sistema deve ser capaz de aumentar o ganho conforme a profundidade, compensando a redução da amplitude. Um dos principais problemas é que a variação da atenuação com a profundidade não é uniforme. Assim, o algoritmo de controle torna-se mais complexo. Utilizando esta tecnologia, os defeitos podem ser localizados com uma resolução de 0,02 metros no comprimento da tora e 0,04 metros em suas dimensões.

2.4.4 Micro-ondas

O uso de micro-ondas para detectar irregularidades na madeira baseia-se nas propriedades de interação principalmente relacionado ao teor de água e à geometria da estrutura anatômica (orientação do grão), além de sua densidade. As fibras, nas quais as moléculas de água são armazenadas geralmente são orientadas ao longo da direção longitudinal. Desta forma, um efeito importante é a dissipação de energia em forma de calor devido à interação do campo elétrico da onda com as moléculas de água contidas nas fibras (Baradit; Aedo; Correa, 2006). Enquanto as constantes dielétricas da madeira aumentam com o aumento da densidade, módulo de elasticidade e força, estas propriedades são diminuídas com o aumento do ângulo entre a direção do campo elétrico e a orientação das fibras da madeira (AlyMattarneh, et al., 2001).

AlyMattarneh, Ghodgaonkar e Majid (2001) apresentam um sistema de inspeção de placas de madeira que opera na faixa de frequência de 8-12,5 GHz. Segundo o mesmo, a principal vantagem deste sistema é o fato de ser possível realizar medições precisas em materiais em condições de alta ou baixa temperatura e condições ambientais eletromagnéticas complexas, como radiação ionizante, por

exemplo. É constituído por um par de antenas de lente homocêntricas focais com duas lentes plano-convexas iguais montadas em uma antena cônica. Uma lente plano-convexa dá uma onda de plano eletromagnético enquanto a outra concentra a radiação eletromagnética no foco.

Baradit, Aedo e Correa (2006) propõem um sistema contendo um diodo detector de tipo *Schockley*, que faz a varredura das peças ao longo das direções previamente selecionadas com um passo de 0,5 cm, além de sistema para aquisição e equipamento emissor de micro-ondas de 15 mW de potência e frequência fundamental de 10,5 GHz. Desta forma, uma série de gráficos foram obtidos para a amostra expressa como valores de tensão versus coordenadas de varredura e desta forma, fez-se o mapeamento 2D e 3D. No referido trabalho, foi verificado que a difração nas bordas de madeira produz fortes variações nos níveis de tensão, correspondendo a sinais indesejáveis que devem ser eliminados da análise. Além disso, a não homogeneidade da madeira devido à sua estrutura anatômica complexa produz variações de tensão entre duas posições para o mesmo sistema.

2.4.5 LASER

As tecnologias que utilizam Amplificação de luz por Emissão Estimulada de Radiação (*Light Amplification by Stimulated Emission of Radiation* – LASER) são empregadas há bastante tempo no setor de controle de qualidade de indústrias madeireiras. Antes, eram somente utilizadas para a classificação de troncos de madeira e para coletar informações como diâmetro, cone, curvatura e comprimento. Uma vez coletados, os dados eram utilizados para definir um padrão ou modelo de corte mais adequado a cada tora (Thomas, et al., 2003). Com o passar do tempo, alguns autores desenvolveram alguns trabalhos buscando também o reconhecimento de defeitos vinculados à madeira, utilizando equipamentos convencionais a laser.

Um sistema de varredura a LASER tridimensional é apresentado por Thomas et al. (2003), onde as detecções de variações internas do material são relacionadas a variações externas. Em quase todos casos, existe um defeito interno localizado logo abaixo de um defeito de superfície associado. Solavancos, por exemplo, geralmente indicam nós, ramos ou feridas ou então, caso possuam cavidades ou furos no meio, indicam que o material em excesso se decompôs. Para o caso de distorções circulares, ou anéis em torno de uma área central achatada, há indicação de um ramo

que foi podado e coberto naturalmente há bastante tempo e conseqüentemente, pode ter gerado um nó *rotten* ou outro defeito interno. Para o caso onde a alteração de altura é menos significante, outros fatores devem ser levados em conta na inspeção, como a forma do defeito e a textura da casca. Para este tipo de inspeção, utilizou-se um scanner de linha a laser de quatro cabeças industrial capaz de gerar imagens de perfil de alta resolução da superfície de uma tora onde buscava-se a localização de nós encobertos, nós decompostos, furos e ramos removidos. A imagem adquirida é processada usando uma abordagem estatística onde busca-se estimar a superfície através do posicionamento de círculos e assim, estimar mudanças de altura sobre esta. O scanner de toras pode inspecionar 4,9 metros de comprimento com baixa resolução em menos de 10 segundos. No entanto, o nível de ruído no sistema é alto e alguns defeitos mais sutis não puderam ser classificados.

Törmänen e Mäkynen (2009) propuseram um método para medir a localização e o tamanho de nós em superfícies de madeiras folheadas utilizando varredura a LASER através do efeito *tracheid*. Esse efeito, recebe este nome graças às células constituintes da madeira, as traqueídes. Elas são orientadas paralelamente à direção do grão e conduzem de forma mais eficiente a luz em sua direção longitudinal do que transversal, fazendo com que a luz que penetra na superfície da madeira seja espalhada principalmente também em sua direção. Desta forma, um feixe de luz estreito projetado para uma superfície de madeira sem defeitos formará um padrão de espalhamento em forma de uma elipse alongada na direção da fibra da madeira no ponto de incidência. Sobre os nós, haverá uma dispersão de luz redonda, uma vez que a orientação das células nestes locais seja perpendicular à orientação das fibras na madeira limpa. Assim, neste método, uma superfície de folheado foi digitalizada projetando linhas de pontos laser individuais e criando imagens com uma câmera industrial de visão de máquina. As superfícies inspecionadas foram iluminadas usando quatro fontes de laser de diodo *Lasiris* com um feixe circular focalizável e um comprimento de onda de 660 nm e potência de saída de aproximadamente 1,3 mW. Os resultados mostraram que o método é capaz de detectar nós independentemente do tipo ou cor, sendo o aspecto limitante o tamanho do nó, que deve ser de no mínimo 5 mm de comprimento. A acurácia encontrada durante a classificação de 101 nós foi de 88,1%.

2.4.6 Raio X

Quando os raios X passam pela madeira, parte da energia de radiação é absorvida pela mesma e somente a parte não absorvida chega ao detector, durante a aquisição de imagens, em uma máquina com esta tecnologia. A quantidade de energia absorvida depende da densidade do material. Sabe-se que a densidade dos nós é o dobro da madeira normal (Oh, et al., 2009). Assim, pode-se obter informações de defeitos internos de madeira de acordo com a variação de densidade na madeira a partir de uma tela de absorção de raios X, mas é necessária a combinação de várias técnicas de processamento de imagem após sua aquisição (Qi; Li, 2007).

Existem duas formas preferenciais de inspeção de defeitos na madeira utilizando-se este tipo de tecnologia: passagem única e tomografia computadorizada. A diferença entre ambas está na forma de aquisição das imagens, uma vez que a primeira seja constituída com a irradiação e captação em apenas um plano de uma única vez e a segunda, em várias etapas, resultando em uma seção transversal (Hansson; Enescu; Brandt, 2015; Longuetaud, et al., 2012; Oh, et al., 2009).

2.4.6.1 Inspeção por raio X de passagem única

Alguns sistemas realizam a inspeção em uma única passagem do raio x, que consiste em um tubo de raios-X e um detector destes raios adquirindo imagens geradas a partir de uma única seção de madeira, indicando principalmente as diferenças de densidade encontradas internamente (Oh, et al., 2009). Qi e Li (2007) propõem a utilização de uma máquina de raios-X industrial para fazer a análise de toras. Hansson, Enescu e Brandt (2015) utiliza um protótipo de máquina de varredura de raios-X para inspecionar tábuas com tipicamente 3 cm de espessura, onde após o processamento de imagem, faz-se uma classificação baseada em análise de texturas. A acurácia encontrada foi de 91,7% na análise de 20 amostras de madeira para detecção de nós internos de toras.

Mu e Qi (2008) adotam a máquina de raios x para irradiar a seção transversal de troncos. A imagem é formada em tela fluorescente onde o material de fluorescência é espalhado. Todo o sistema centra-se no computador para finalizar várias operações e processamento de imagem digital. Durante o processamento, a imagem em tons de cinza é convertida em imagem binária. Para melhorar a eficiência de detecção dos defeitos, utiliza-se um filtro de mediana para segmentar a imagem original. Por fim,

aplica-se um pós-processamento para a detecção de bordas de nós *rotten* em imagem com fundo escuro. Neste trabalho foram identificados somente nós vivos, furos e nós decompostos. O sistema foi avaliado utilizando 150 amostras, obtendo-se 90% de precisão para detecção e diferenciação entre dois tipos de nós e furos.

Oh et al. (2009) utilizam um equipamento de varredura de raios-X que consiste em um tubo de raios X, um escudo para proteção e um detector. O coeficiente de atenuação de massa foi determinado experimentalmente para cada espessura da amostra. As imagens foram tiradas em seções transversais contendo nós. As amostras foram configuradas para permitir que os raios X passassem através da espessura de 38 mm da amostra. Neste estudo, foi proposto o método de avaliação da razão de profundidade do nó (*Knot Depth Ratio* - KDR), em relação à largura da madeira serrada. Este método foi desenvolvido para medir a quantidade geométrica de nós em uma seção transversal e estimar a resistência mecânica do material, que é inversamente proporcional à incidência destes defeitos, uma vez que a resistência dos nós seja relativamente menor do que a da madeira “limpa”. Este método foi proposto devido ao fato de que outros métodos não destrutivos podem determinar a presença de nós, mas sem o correto detalhamento das características mecânicas da madeira. Nos resultados houveram discrepâncias na estimativa de valores de KDR encontrados porque a densidade da madeira dita como tardia é muito maior do que recente. Além disso, para este sistema, os raios X não podem distinguir entre nó e zona de transição porque a densidade da zona de transição é semelhante à dos nós.

2.4.6.2 Tomografia Computadorizada

A detecção dos defeitos internos de toras de madeira via tomografia computadorizada pode ser feita através da análise da imagem de uma única seção transversal, como é implementado por Sarigul, Abbott e Schmoldt (2003), ou então, conforme abordado por outros autores, através da reconstrução 3D dos troncos a partir de seções 2D visando à maior gama de informações possíveis sobre essas deformidades.

Bhandarkar e Tang (1998) descrevem um sistema baseado em visão por computador e tomografia para o planejamento da produção de madeira. O sistema também reconhece defeitos visando à formulação de estratégias de corte para otimização do rendimento da madeira. Para tanto, as imagens 2D obtidas, das “fatias”, obtidas pela tomografia são usadas para a reconstrução 3D e renderização da

madeira e seus defeitos internos. Assim, o sistema destina-se a auxiliar o planejamento da produção de madeira, conforme suas dimensões e defeitos internos, otimizando operações como serragem e recorte. As imagens de tomografia computadorizada (*Computed Tomography* – CT) das toras são capturadas usando um *scanner Toshiba TCT 20AX CT* com uma resolução de 0,75 " por 0,75". Uma vez que um nó é um ramo embutido no tronco de uma árvore, o ângulo entre o mesmo e o eixo da medula do tronco da árvore é geralmente cerca de 45°. Essa informação é utilizada para distinguir um nó de outros objetos brilhantes, como um bolso de água. Outras medidas 3D são utilizadas para classificar um defeito como nó, como por exemplo o seu formato, que tipicamente é elíptico.

Um método totalmente automatizado capaz de reconhecer nós de imagens de raios-X por tomografia computadorizada de um pedaço de madeira e obter dados sobre a geometria do nó sem qualquer intervenção humana é proposto por Longuetaud et al. (2012). As amostras foram analisadas usando um dispositivo de varredura *BrightSpeed Excel*, projetado para uso médico. Nesse estudo, seis dos sete feixes foram escaneados com o gerador de raios-X ajustado para 120 kV-50 mA, e uma espessura de fatia e intervalo entre fatias de 3,75 mm. Os desafios foram maximizar a taxa de detecção de nó, minimizar os falsos alarmes e obter uma descrição geométrica precisa e completa do nó com informações como localização, diâmetro, volume, inclinação e outros. O algoritmo foi desenvolvido para a detecção de nós em troncos de Abeto de Prata e Abeto da Noruega. O algoritmo foi capaz de detectar um total de 85% de 428 nós.

2.4.7 Sensores de Ondas de Tensão

Geralmente, uma onda de tensão se propaga mais rapidamente em madeira dura de alta densidade e mais lenta em madeira macia de baixa densidade (Li-hai, et al., 2007). Assim, ao medir o tempo de transmissão da onda, pode-se avaliar as condições físicas dentro de uma tora. Para tanto, um sensor é utilizado para ocasionar vibração e produzir uma onda de tensão que será propagada na madeira e recebida por outros sensores. O intervalo de tempo no processo é gravado para calcular a velocidade de propagação da onda de tensão entre dois sensores.

Li-hai, et al (2007) implementam um sistema utilizando o aparelho de teste de ondas de tensão, *Arbotom*, fabricado na Alemanha, juntamente com um medidor de

umidade das toras ST-85, além de um computador pessoal para, além de mensurar as propriedades do material, compensar os efeitos da umidade. São adotadas figuras geométricas para estimar a circunferência aproximada da madeira e a forma de seus defeitos, por exemplo, um racho (ou quebra) é um triângulo ou retângulo. São colocados pinos na circunferência da tora, onde são fixados os sensores de forma ordenada, mantendo sensores e pinos perpendiculares. A quantidade de sensores tem grandes efeitos sobre a precisão do teste de defeitos de toras usando a onda de tensão. O aumento apropriado da quantidade de sensores pode melhorar o grau de montagem da imagem e reduzir a taxa de erro e, finalmente, melhorar a precisão do teste de onda de estresse. Para toras com diâmetros que variam de 20 a 40cm, foram necessários pelo menos 12 sensores para atender ao requisito que garante uma taxa de erro de 0,1. Enquanto 10 sensores podem apenas avaliar os locais possíveis de defeitos e 6 são suficientes para decidir se existem defeitos ou não.

2.4.8 Ultrassom

Sendo a madeira um material altamente anisotrópico, com velocidades sonoras de 1200 a 5000 m/s, dependendo da orientação da fibra de madeira, pode-se medi-las e relacioná-las à qualidade da madeira, uma vez que defeitos como nós causem alterações no ângulo do grão (Schafer, 2000). Defeitos diferentes também podem ser detectados e discriminados usando combinações diferentes de parâmetros básicos da forma de onda como intensidade e tempo entre transmissão e recepção. A velocidade do som muda à medida que o ângulo do grão tende à perpendicularidade. Além disso, as ondas sofrem distorções quando passam por regiões de diferentes velocidades e o mesmo acontece com regiões que possuem nós e a madeira limpa. Outra propriedade da madeira é a atenuação, a qual varia de acordo com a direção da orientação da fibra. Os sinais que viajam ao longo dela estão sujeitos a uma atenuação significativamente menor do que aqueles que viajam de forma não paralela às fibras. Assim, a detecção de nó depende da classificação de distorções de sinal causadas por mudanças na orientação do grão. Os transdutores de ultrassom a serem utilizados por tal aplicação devem ser capazes de emitir energia suficiente para propagar ondas sonoras dentro e fora da madeira.

Um sistema construído com múltiplos transdutores de ultrassom é apresentado por Schafer (2000). Estes operam de 120 a 400 kHz dependendo da resolução

necessária e da espessura da madeira e foram desenvolvidos utilizando tecnologia piezocompósitos. Todos os transdutores desenvolvidos são cobertos por uma capa de uretano que fica sobre a madeira, garantindo um melhor contato.

2.4.9 Câmera

Embora outros sensores para detecção de defeitos em madeira tenham produzido bons resultados em escala laboratorial, é difícil que sejam aplicados em indústrias de pequeno porte, devido aos custos envolvidos (Nagai, Murata e Nakano 2009). Por isso, sistemas de visão com câmeras ainda são mais popularizados para tal função e são empregados na maior parte dos trabalhos desenvolvidos na área do controle de qualidade da madeira.

Uma forma de inspecionar nós em folheados de madeira, com a utilização de câmeras é proposto por Todoroki, Lowell e Dykstra (2010), onde são feitas imagens das peças inteiras, com dimensões de 10,7 m por 5,5 m de uma única árvore de Abeto de Douglas. Nesse trabalho, a análise fotográfica foi baseada em imagens digitais de alta resolução de 3872 × 2592 pixels em escalas de vermelho, verde e azul (*Red, Green and Blue – RGB*) de 24 bits onde foi utilizada uma câmera Nikon D80 montada a cerca de 3 m acima da madeira. Para iluminação, foram utilizadas duas lâmpadas de quartzo de 600 W, montadas a cerca de 2,4 m acima do folheado em ângulos de 45 °. Foram utilizadas 51 folhas inteiras para a aquisição de imagens. Após adquiridas, as imagens foram segmentadas através de uma série de operações morfológicas para isolar regiões que provavelmente continham nós, além de realinhar a imagem para a janela de visualização e representar os limites da peça a ser inspecionada. Posteriormente, aplicou-se o método de Otsu e limiar adaptativo para imagens segmentadas em tons de vermelho para a classificação. A taxa de verdadeiro positivo encontrada foi de 1,00, 0,99 e 0,96 para o desenvolvimento, treinamento e conjuntos completos, respectivamente, e para a acurácia as taxas encontradas foram 0,76, 0,92, 0,73, respectivamente.

No trabalho de Wenshu, Lijun e Jinzhuo (2015), foi discutida a identificação e posicionamento de defeitos de placas de madeira por visão computacional e tecnologia de rede neural artificial. Para a aquisição de imagens, utilizou-se uma câmera industrial com interface de Barramento Serial Universal (*Universal Serial Bus – USB*) *Daheng* modelo DH-HV1351UM, com resolução de 1,3 milhões de pixels e

sensor tipo Dispositivo de Carga Acoplada (*Charge-Coupled Device* – CCD). A segmentação das imagens se deu pela conversão da imagem em tons de cinza e posteriormente, sua filtragem por filtro de mediana. Com isso, buscou-se a eliminação de ruído, a suavização de imagem e extração das bordas. Todos os pixels nas áreas adjacentes à janela do filtro foram classificados de acordo com seu nível de escala de cinza através de estatística. Finalmente, todos os pixels da janela receberam um valor médio. Fez-se também a detecção de bordas, utilizando-se operador *Sobel*, que é capaz de não só detectar borda dos nós, mas também eliminar algum ruído adicional e garantir que a imagem adquirida tenha poucas descontinuidades. É especialmente bom no processamento de imagens em escala de cinza e possui alta sensibilidade de detecção. Por fim, segundo os autores, com a aplicação da rede neural, obteve-se uma taxa de 86,67% de acerto durante a identificação dos defeitos.

Zhang et al. (2015) e Li et al. (2017) propõem sistemas semelhantes para o reconhecimento de três defeitos comuns em placas de madeira: *dead knots*, *live knots* e rachaduras de madeira. A espécie de madeira testada foi a *Xylosma* e o tamanho das peças a inspecionadas nos experimentos é de 40x20x2 cm. Utilizou-se uma câmera Oscar F810C IRF para a aquisição das imagens, com o auxílio de dois diodos emissores de luz (*Light Emitting Diode* – LED) em paralelo usados na iluminação para tornar as imagens adquiridas mais claras. As mesmas foram constituídas com níveis de cinza de 8 bits e resolução de 128x128 pixels para treinamento. Para reduzir a redundância de dados e a dimensionalidade das funções, além de melhorar a precisão da identificação, Zhang et al. (2015) utilizam o método de Análise de Componente Principais (*Principal Component Analysis* – PCA) para projeção dos dados em um espaço dimensional menor. Para a classificação, o mesmo utiliza uma rede neural tipo Mapa Auto-Organizável (*Self Organizing Methods* - SOM). Com isso, obteve-se uma acurácia de 92%, com tempo médio de detecção de 0,2015 ms. Enquanto que Li et al. (2017) implementam um método de detecção baseado na análise de discriminante linear (*Linear Discriminant Analysis* - LDA) para reduzir o tempo de processamento. O sistema obteve uma acurácia 94% para a classificação, utilizando o mesmo tipo de classificador. O tempo médio para o processamento foi de 0,446 ms.

Os sistemas ópticos para inspeção de defeitos de madeira também podem ser interligados a outros equipamentos, como descrito por Hu et al. (2011), que utilizam um sistema de visão compacto (CVS 1456, NI), uma câmera CCD (*Balser scA 1390-17 fc*, *Balser Vision Technologies*), duas lâmpadas (Toshiba 150WF), uma mesa de

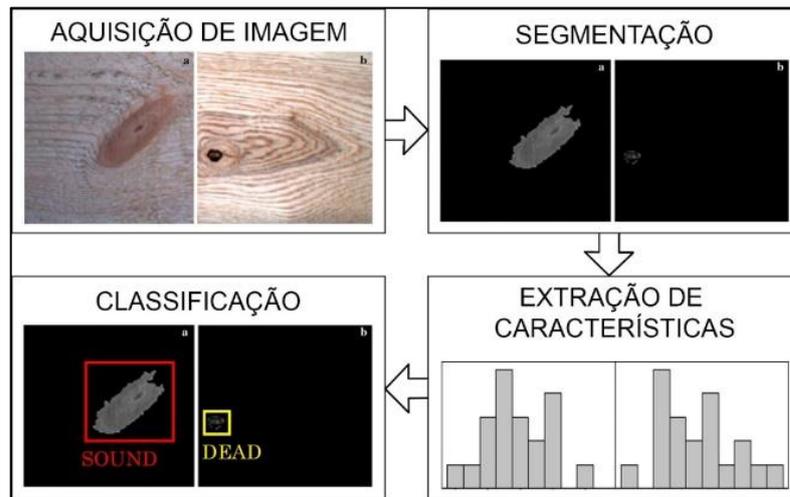
trabalho de Comando Numérico Computadorizado (CNC) (série Funuc M180) e um computador *host*. Foram utilizadas 222 amostras de *Sugi (C. japonica L.f.)* de 1.000×300×20mm para determinar adequadamente as regras de reconhecimento. As imagens foram capturadas em 60 pontos por polegada (*dots per inch – dpi*) e foram gravadas como imagens RGB de dimensões de aproximadamente 270×200 mm. Sob o estudo, a imagem cinza foi usada para detectar as regiões de defeito em potencial e os sinais R, G e B foram usados para identificar o tipo de nó. Para localizar com precisão regiões potencialmente defeituosas, o algoritmo de Otsu foi usado para selecionar automaticamente o limiar do histograma do parâmetro de contraste com base na imagem cinza. A imagem então, foi convertida em uma imagem binária que expressava os defeitos potenciais e áreas de madeira limpas. Uma operação morfológica foi conduzida para eliminar o ruído após a segmentação. A abordagem que foi construída de acordo com os histogramas de características de cores, foi usada para classificar os tipos de nó. Quatro características básicas, que foram as variações do sinal R, G, B, e a média do sinal G, foram utilizadas para identificar os defeitos. Uma série de amostras foram selecionadas aleatoriamente para verificar a eficiência e precisão do sistema proposto. A precisão para localizar as posições de nós *sound* e nós *loose*, que é um tipo nó prejudicial, foi de 94,7% e 97,6%, respectivamente, e a precisão de classificação para os tipos de nós, 96,6% e 98,8%. A acurácia geral de detecção do sistema foi de 93,9%.

2.5 SISTEMAS BASEADOS EM CÂMERA

Os sistemas de detecção de defeitos em madeiras que utilizam câmeras podem realizar a operação em três etapas: segmentação, extração de características e classificação, conforme ilustra a Figura 3. A etapa de segmentação tem por objetivo isolar a região que abrange os nós e outros defeitos da madeira limpa. Dessa forma, torna-se possível encontrar a localização e o tamanho dos mesmos (Wenshu; Lijun; Jinzhuo, 2015; Li, et al., 2017; Hu, et al., 2011). Trabalhos recentes utilizam os métodos de Otsu, Matriz de Co-ocorrência de Nível de Cinza (*Gray-Level Co-Occurrence Matrix - GLCM*), Padrão Binário Local (*Local Binary Pattern - LBP*) e morfologia matemática para esta função. A segunda etapa busca a relação de similaridade entre diferentes defeitos de madeira através da extração de características baseadas em cores, texturas ou mesmo formatos (Xiang, et al., 2016;

Li, et al., 2017). Para o caso de texturas, também podem ser utilizados os métodos de Otsu, GLCM e LBP. Por fim, diversos tipos de classificadores podem ser utilizados para a terceira etapa, no entanto, a Máquina de Vetor de Suporte (*Support Vector Machines* - SVM) e redes neurais artificiais são os mais utilizados e apresentam os melhores resultados.

Figura 3 – Diagrama de um sistema para detecção de defeitos de madeira baseado em câmera.



Fonte: Adaptado de Li et al. (2017).

2.5.1 Extração de características

Grande parte dos trabalhos desenvolvidos na área busca uma análise de texturas e, por isso, trabalha com a extração de características vinculadas a elas. Marcano-Cedeño et al. (2009) utilizam um banco de filtros *Gabor* para tal função. Estes filtros são de passagem de banda seletivos 2D em relação à frequência e orientação. Operam diretamente na imagem no domínio espacial, sem a necessidade de ter que se trabalhar no domínio das frequências. Os filtros *Gabor* constituem um banco de filtros onde cada filtro é dilatado, transladado e rotacionado em relação um ao outro e a definição matemática é dada por

$$\psi_{f,\theta}(x,y) = \exp\left(i(f_x x + f_y y) - \frac{f^2(x^2 + y^2)}{2\sigma^2}\right) \quad (1)$$

onde

$$\begin{aligned} f_x &= f \cos \theta \\ f_y &= f \sin \theta \end{aligned} \quad (2)$$

$$i = \sqrt{-1}$$

x e y são coordenadas de pixels da imagem, f é a frequência central do filtro passa banda, θ é a orientação do filtro e σ é a largura de banda. A convolução da imagem $I(x,y)$, com $(x,y) \in \Omega$ (Ω - conjunto de pontos de imagem) com a função *Gabor* 2D $\psi(x,y)$, $(x,y) \in \Omega$ corresponde à Transformada de *Gabor* de uma imagem. Para o desenvolvimento do referido trabalho, utilizaram-se informações sobre a magnitude para o filtro e um conjunto de 36 bancos de filtros foi implementado, com 6 frequências e 6 orientações. Foram utilizadas imagens em escala de cinza normalizadas para o tamanho de 32x32 pixels como entrada, onde cada uma é convolucionada com o banco de filtros, gerando 36 imagens filtradas diferentes, com informações de frequência e orientação. Cada imagem de saída é concatenada por linhas para construir um vetor de características, $Y\psi(f, \theta)$ de dimensão 1024x36.

Outra forma de análise de texturas e suas características comumente utilizada é baseada em *Gray-Level Co-Occurrence Matrix* (GLCM), que consiste na determinação da probabilidade de ocorrência do mesmo nível de cinza em diferentes pixels da imagem. Para detecção de defeitos de madeira por este método, YongHua e Jin-Cong (2015) contam com a extração de 5 características de textura, visando à otimização da classificação. São eles: o segundo momento, o contraste, a correlação, a variância e a entropia. Nesse trabalho, são selecionados campos de 15x15 por vez para calcular o GLCM. Forma-se então a matriz de co-ocorrência, de acordo com a localização de cada campo da janela, considerando os parâmetros de textura centralizados à mesma. Por fim, a imagem inteira de 512x512 é percorrida e são removidos os efeitos da borda. Cada imagem gera 248004x5 parâmetros de textura. A expressão da GLCM é dada por:

$$\begin{aligned} Fp(i, j, \delta, \theta) &= \{(x, y) | f(x, y) = i, f(x + Dx, y + Dy) = j; x, y \\ &= 0, 1, 2, \dots, N - 1\} \end{aligned} \quad (3)$$

onde Dx e Dy referem-se à distância entre os pontos correspondentes aos níveis i e j , para $i, j = 0, 1, 2, \dots, L - 1$, x, y são as coordenadas dos pixels na imagem (YongHua, et al., 2015), L é o número de níveis de cinza, δ é o número de pixels em intervalos adjacentes e θ representa a direção.

O *Local Binary Pattern* (LBP) é um algoritmo usado para descrever as características de textura local da imagem (Xiang, et al., 2016). Em um pixel central,

um número padrão é calculado e definido como limiar para que possa ser comparado com seus pixels vizinhos. Se o pixel adjacente ao central for maior ou igual ao dos pixels adjacentes, é marcado como 1, de outro modo, marcado como 0. O LBP de um pixel central definido pelas coordenadas (X_c, Y_c) pode ser estimado por

$$LBP(X_c, Y_c) = \sum_{p=0}^{p-1} S(i_p - i_c) 2^p \quad (4)$$

onde i_c o brilho e i_p o brilho dos pixels adjacentes. A função $S(x)$ é dada por

$$S(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (5)$$

As características de textura de madeira são representadas na forma de histograma LBP. Xiang et al. (2016) selecionaram 59 dessas características e aplicaram o χ^2 (qui quadrado) para calcular a similaridade entre estes histogramas obtidos de imagens diferentes contendo nós. Desta forma, histogramas de defeitos semelhantes, possuem valores de χ^2 inferiores em relação aos diferentes entre si. Além disso, o autor faz uma comparação entre os métodos LBP e GLCM, encontrando melhores resultados com menor tempo de processamento para a implementação do primeiro, durante experimentos na detecção de defeitos em madeira.

Para Duda, Hart e Stork (2001 pp. 15-45), o desempenho de um classificador geralmente é prejudicado com um número excessivo de dimensões, mesmo que estas características sejam úteis. Este fenômeno é conhecido como “maldição da dimensionalidade” e foi assim chamado primeiramente por Bellman (1961) devido à dificuldade em realizar a integração numérica de alta dimensão. Como demonstrado pelo mesmo, 100 pontos de amostra uniformemente espaçados são suficientes para amostrar um intervalo unitário com uma distância não superior a 0,01 entre os pontos. Enquanto que uma amostra equivalente de um espaço de 10 dimensões com espaçamento de 0,01 em rede entre pontos adjacentes exigiria 10^{20} amostras. Ou seja, o hiper-volume cresce exponencialmente com a adição de novas dimensões, com isso, os dados se tornam mais esparsos e suas similaridades podem ser reduzidas. A única maneira de vencer a maldição, segundo Li et al. (2017) e Duda, Hart e Stork (2001), seria incorporar conhecimento sobre os dados corretos a serem utilizados como características. A aplicação do método LDA, também conhecido como

discriminante de Fisher, pode ser uma solução para tal problema, visto que além de desempenhar tal função, pode maximizar a distribuição da amostra entre as classes e minimizar a distribuição da amostra dentro da classe para melhorar o desempenho da classificação. Considerando $X = \{x_1, x_2, \dots, x_n\}$ como um conjunto de vetores características no \mathfrak{R}^d e o problema possuir c classes, as definições da matriz de dispersão entre classes S_b e da dispersão na própria classe S_w são expressas como:

$$S_b = \sum_{i=1}^c n_i (u_i - u)(u_i - u)^T \quad (6)$$

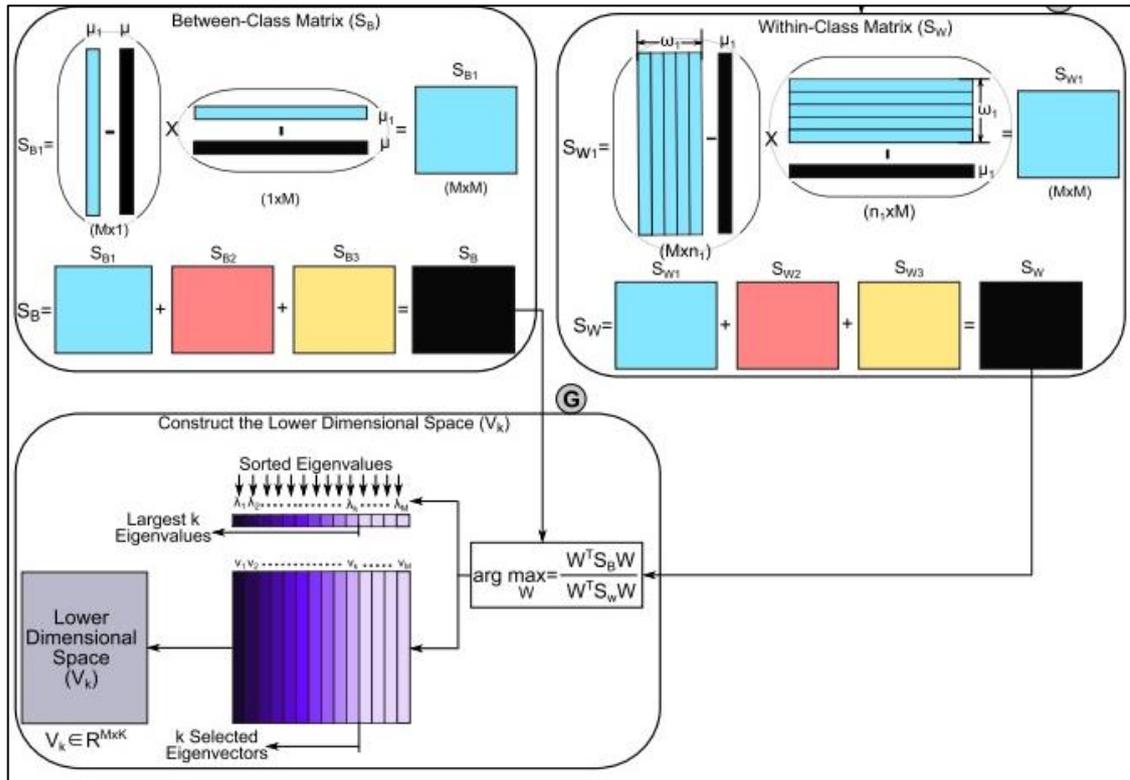
$$S_w = \sum_{i=1}^c \sum_{x_k \in \text{classe } i} (u_i - x_k)(u_i - x_k)^T \quad (7)$$

onde n_i é o número de amostras pertencentes à classe i , u é o valor da média de todas as amostras e u_i é o valor da média das amostras pertencentes à classe i . O LDA pode ser expresso por:

$$S_b^{-1} S_w w^* = \lambda w^* \quad (8)$$

onde w^* é o vetor de projeção otimizado calculado pelos vetores de características do valor máximo de $S_w^{-1} S_b$. Quando w^* é obtido, as amostras de d dimensões podem ser projetadas para um espaço unidimensional. λ representa os autovalores. Os autovetores representam as direções do novo espaço, e os autovalores correspondentes representam o fator de escala, o comprimento ou a magnitude dos autovetores. Assim, cada autovetor representa um eixo do espaço LDA, e o autovalor associado representa a robustez desse autovetor. A robustez do autovetor significa aumento da variância entre classes e diminuição da variância dentro de cada classe. Assim, os autovetores com os autovalores mais altos são usados para construir um espaço dimensional menor (V_k), conforme Figura 4 (Tharwat, et al., 2017).

Figura 4 – Diagrama de blocos da redução do espaço de características através do LDA.



Fonte: Adaptado de Tharwat, et al (2017).

Gu, Andersson e Vicen (2010) buscam a determinação de uma cor média de uma determinada região defeituosa normalizada em relação aos valores máximos de cores de todas as imagens de treinamento através da utilização de um filtro estatístico de ordem (*Order Statistic Filter – OSF*). Um filtro estatístico de ordem não linear (ou *L-estimator*) é aplicado nas cores obtendo uma média conforme a seguinte equação

$$F(G(s^{(1)}), G(s^{(2)}), \dots, G(s^{(N)})) = \sum_j \alpha_j G(s^{(j)}) \quad (9)$$

onde $G(s^{(i)})$ é a cor filtrada obtida pela convolução linear do *kernel* do filtro pela cor original, e sendo

$$\alpha_j = \begin{cases} \frac{1}{L}, & \text{se } i = (N - L + 1)/2 \\ 0, & \text{de outra forma} \end{cases} \quad (10)$$

e o parâmetro L determinado empiricamente. Primeiramente, os limites externos dos nós são obtidos. Com isso, determinam-se os conjuntos de pixels que correspondem às áreas externas dos defeitos, à borda dos mesmos ou então ao seu interior. Em seguida, é criado um vetor de características contendo informações como tamanho

do nó e as “pseudo” cores obtidas pela aplicação do filtro, correspondentes às três regiões de cada nó. O filtro deve ser configurado para que a imagem de cor filtrada contenha textura média suficiente e informação dos limites do nó, suavizando, no entanto, os detalhes finos da madeira. A implementação do filtro também busca reduzir as variações de cor da madeira devido às origens da madeira e do tipo de madeira, e devido a condições de iluminação.

Outro tipo de característica utilizada para detecção de nós são as chamadas características geométricas (Li, et al., 2017). Algumas das características incluem área, perímetro, comprimento e largura do retângulo delimitador do nó, compacidade, que é uma relação entre área e perímetro das formas e retangularidade, que é a medida de quanto uma forma se aproxima de um retângulo, relacionando a sua área com a área de um retângulo mínimo capaz de sobrepor a forma em questão (Geomatrics). Além disso, pode-se utilizar medidas referentes ao formato elíptico como excentricidade, eixo curto e eixo longo.

Por fim, também são utilizadas configurações de sistemas para inspeção da qualidade da madeira, que contam com as extrações de características estatísticas. É o caso de Hu et al. (2011), que após a segmentação, buscam a extração de propriedades como a média da componente verde do RGB e as variâncias das três camadas de cores. Neste contexto, Li et al. (2017) utilizam média, desvio padrão, terceiro momento, e sete momentos invariantes com diferentes ordens.

2.5.2 Classificadores de nós

Grande parte dos trabalhos recentes para o reconhecimento de defeitos em madeira utilizam redes neurais. Essas redes, segundo Haykin (1999 pp. 156 - 159), basicamente são formadas por unidades de processamento denominadas neurônios que tem o papel de armazenar conhecimento experimental através das “forças de conexão” entre os neurônios, conhecidas como pesos sinápticos e outras funções da rede. Cada neurônio recebe os sinais de entrada e os pondera pelos respectivos pesos das sinapses para posteriormente somá-los. A amplitude de saída do neurônio é limitada pela função de ativação. Além disso, pode-se utilizar uma polarização externa (bias) para transformar a saída do somador. Redes neurais podem ser não-lineares o que é uma propriedade altamente importante, uma vez que diversos sinais de entrada possam ser também não-lineares. Além disso, as Redes Neurais Artificiais

(RNAs) não requerem prévio conhecimento sobre a distribuição dos dados, bastando apenas que haja uma relação implícita entre os dados. São utilizadas geralmente redes Perceptron de Multi Camadas (do inglês *Multilayer Perceptron* - MLP) e *Self-Organizing Map* (SOM) (YongHua; Jin-Cong, 2015; Xiang, et al., 2016; Marcano-Cedeño; Quintanilla-Domínguez; Andina, 2009; Li et al., 2017; Zhang, et al., 2015).

Alguns trabalhos utilizaram Máquinas de Vetor de Suporte (do inglês *Support Vector Machines* - SVM), obtendo taxas altas de precisão na classificação de defeitos de madeira, em relação aos trabalhos anteriores (Gu; Andersson; Vicen, 2010; Hittaweá, et al., 2015). A grande diferença desse classificador para as redes neurais é que não se busca a redução da dimensionalidade do espaço de características, mas sim a distribuição mais adequada para os dados de entrada visando a melhor aplicação do discriminante bem como a redução do erro de generalização (Gu; Andersson; Vicen, 2010).

2.5.2.1 Multilayer Perceptron

As *Multilayer Perceptron* (MLP) são redes que possuem aprendizado supervisionado, ou seja, envolvem a modificação dos pesos sinápticos da RNA através da aplicação de um conjunto de amostras de treino, para as quais se conhece previamente a saída desejada da rede Haykin (1999 pp. 156 - 159). Esses pesos são modificados visando à minimização da diferença entre a resposta desejada e a resposta atual da rede, produzida pelo sinal de entrada, de acordo com algum critério estatístico apropriado. As unidades de entrada representam os componentes de um vetor de características e os sinais emitidos pelas unidades de saída serão funções discriminantes usadas para classificação (Duda; Hart; Stork, 2001). Cada unidade escondida executa a soma ponderada de suas entradas para formar sua ativação da rede. Ou seja, a ativação da rede é o produto interno das entradas com os pesos na unidade oculta. De uma forma simplificada, considerando o valor de característica $x_0 = 1$ e o seu respectivo valor de peso como w_0 então, pode-se escrever a equação de ativação da rede como

$$net_j = \sum_{i=1}^d x_i w_{ji} + w_{j0} = \sum_{i=1}^d x_i w_{ji} = \mathbf{w}_j^t \mathbf{x} \quad (11)$$

onde o índice i corresponde às unidades na camada de entrada e j , à camada oculta. w_{ji} indica os pesos nas conexões que ligam a camada de entrada para a oculta (sinapses). Cada unidade oculta emite uma saída que é uma função não-linear de sua ativação que também pode ser chamada de função de transferência.

Para a classificação, tem-se uma unidade de saída para cada categoria, e o sinal de cada unidade de saída é uma função discriminante não linear $g_k(\mathbf{x})$, que pode ser expressa como:

$$g_k(\mathbf{x}) = f \left(\sum_{j=1}^{n_H} w_{kj} f \left(\sum_{i=1}^d w_{ji} x_i + w_{j0} \right) + w_{k0} \right) \quad (12)$$

onde k indexa as unidades na camada de saída e n_H indica o número de camadas ocultas.

Com a implementação deste tipo de classificador, YongHua e Jin-Cong (2015) atingiram uma acurácia para a classificação de nós de 91,3%, com tempo médio de operação de 1,56 segundos. Os resultados foram obtidos a partir de uma base de dados contendo 150 amostras para testes. Xiang et al. (2016), conseguiram uma taxa de 93%, em 90 amostras de teste. Além destes, Marcano-Cedeño, Quintanilla-Domínguez e Andina (2009) propõem uma implementação otimizada com a utilização de um algoritmo denominado *Artificial Metaplasticity*. Em razão disso, foi alcançada uma acurácia de 97,9% para uma base de 48 imagens para teste.

Quando não há informação acerca dos dados a serem classificados, a função de transferência da rede deve ser não-linear. Uma segunda propriedade desejável é que a mesma sature, isto é, tenha valor de saída máximo e mínimo, mantendo os pesos e ativações limitados e, assim, manterá o tempo de treinamento limitado. Uma terceira propriedade é a continuidade e a suavidade, ou seja, que $f()$ e $f'()$ sejam definidos em toda a faixa de seu domínio. Isso porque no aprendizado *backpropagation*, se faz o cálculo da derivada do erro quadrático, visando à sua minimização, que é dado pela saída do *perceptron*. Uma outra propriedade que pode ser importante é a simplicidade computacional. Uma classe de funções que possui todas essas propriedades é o sigmoide, como uma tangente hiperbólica. A função sigmoide é suave, diferenciável, não linear e saturante, além disso, maximiza a transmissão de informações para recursos que são normalmente distribuídos. Uma camada oculta de unidades sigmoideais oferece uma representação global ou

distribuída da entrada. Desta maneira, qualquer entrada específica x é capaz de produzir atividade através de várias unidades ocultas. Por estas razões, o sigmoide é a função de transferência mais amplamente utilizada. As funções sigmoidais anti-simétricas, ou seja, com $f(-net) = -f(net)$, aceleram a aprendizagem, eliminando a necessidade de aprender os valores médios dos dados de treinamento. Assim, funções sigmoidais da forma

$$f(net) = a \tanh(b net) = a \left[\frac{1 - e^{b net}}{1 + e^{b net}} \right] = \frac{2a}{1 + e^{-b net}} - a \quad (13)$$

geralmente tem melhor desempenho (Duda, et al., 2001).

Segundo Zunino e Gastaldo (2002), *Soft-Max* (SM) fornece o suporte para classificação e seleção, na modelagem de fenômenos contínuos. A função *SoftMax* de um vetor Y , de n variáveis escalares de entrada ($Y = \{y_1, \dots, y_n\}$) é um vetor S , de n valores computados como:

$$s_i(Y) = \frac{\exp(-\gamma y_i)}{\sum_{j=1}^n \exp(-\gamma y_j)}; i = 1, \dots, n \quad (14)$$

O parâmetro γ (ganho) rege a forma do mapeamento SM. Valores pequenos de ganho levam a uma operação SM "suave", que suporta assintoticamente uma distribuição uniforme. Conforme Reverdy e Leonard (2016), grandes valores de γ fazem a função SM tender a um comportamento discreto. Esta função é utilizada como métrica para tomada de decisão, considerando-se como um problema de otimização, buscando o valor de i que maximiza a expressão $(-\gamma y_j)$.

À medida que o treinamento da rede avança, as não-linearidades das unidades são expressas e o limite de decisão é distorcido. Sendo assim, a interrupção do treinamento antes da descida gradiente pode ajudar a evitar o *overfitting*. Na prática, o critério elementar de parar quando a função de erro diminui menos do que um valor pré-definido (por exemplo, linha no Algoritmo), não conduz de forma confiável a classificadores precisos, pois é difícil saber antecipadamente qual limite apropriado deve ser definido. Um método é parar o treinamento quando o erro em um conjunto de validação separado atinge um mínimo, ou então a entropia cruzada, para n padrões, dada por:

$$J(W)_{ce} = \sum_{m=1}^n \sum_{k=1}^c t_{mk}/z_{mk} \quad (15)$$

onde t_{mk} e z_{mk} são o alvo e a saída real da unidade k para o padrão m . Naturalmente, essa função de critério requer os valores de ensino e de saída no intervalo (0, 1). Uma análise de segunda ordem do erro, no entanto, pode determinar a taxa de aprendizado ideal. Pode-se usar informações de segunda ordem de maneira mais completa do que outras formas, gerando métodos rápidos de aprendizado. Assumindo a função de critério

$$J(W) = \sum_{m=1}^n (t_m - z_m)^2 \quad (16)$$

onde t_m e z_m são os sinais de destino e de saída e n o número total de padrões de treinamento. Os elementos da matriz hessiana são

$$\frac{\partial^2 J(W)}{\partial \omega_{ji} \partial \omega_{lk}} = \sum_{m=1}^n \frac{\partial J}{\partial \omega_{ji}} \frac{\partial J}{\partial \omega_{lk}} + \sum_{m=1}^n \frac{\partial^2 J}{\partial \omega_{ji} \partial \omega_{lk}} (z - t) \quad (17)$$

onde usamos os subscritos para nos referirmos a qualquer peso na rede - assim, i , j , l e k poderiam assumir valores que descrevem pesos da camada de entrada para a oculta, ou que descrevem pesos da camada oculta para a saída, ou ainda misturas. O segundo termo é da ordem $O(\|t - o\|)$ e usando o método de pontuação de Fisher, define-se este termo para zero. Isto dá o valor esperado, uma matriz positiva definida, garantindo que a descida de gradiente irá progredir. Esta aproximação é chamada de aproximação de Levenberg-Marquardt e é utilizada na função de treinamento *Bayesian regularization backpropagation*, que é a utilizada na rede neural do presente trabalho. Esta função por sua vez, busca uma maior generalização para a rede resultante.

2.5.2.2 Self-Organizing Maps

Li et al. (2017) aplicam redes SOM para classificação de nós de madeira. Os testes foram realizados com 50 amostras e obtiveram uma acurácia de 94% em 0,446 ms. Segundo Haykin (1999 pp. 443 - 453), as SOMs são grades neurais não supervisionadas baseadas na aprendizagem competitiva, de modo que os neurônios de saída competem entre si para serem ativados e apenas um neurônio por grupo é

ligado em um instante de tempo. Desta forma, busca-se a representação de todos os pontos no espaço fonte por pontos em um espaço-alvo cuja dimensão topológica é inferior à original, de modo que os relacionamentos de distância e de proximidade sejam preservados. Pode-se considerar o mesmo como um mapa topográfico dos padrões de entrada onde as localizações dos neurônios são determinadas pelas características estatísticas intrínsecas contidas nos padrões de entrada. A formação do mapa auto-organizado se dá primeiramente pela inicialização dos pesos sinápticos na rede, que podem ser pequenos valores escolhidos de um gerador de números aleatórios. Em seguida, para cada padrão de entrada, os neurônios da rede calculam seus respectivos valores a partir de uma função discriminante. O neurônio com o maior valor é declarado vencedor do processo então denominado como competição. A segunda fase da constituição do mapa é chamada de cooperação e consiste na localização de uma vizinhança de neurônios excitados que se relacionam entre si e com o vencedor. Por fim, os neurônios excitados aumentam seus pesos sinápticos individuais. A presença de redundância nos dados de entrada é necessária para o aprendizado, pois fornece conhecimento.

A essência do processo de competição entre os neurônios pode ser entendida como a busca pelo valor máximo do produto interno $\mathbf{w}_j^t \mathbf{x}$ que é matematicamente equivalente à mínima distância euclidiana entre os vetores \mathbf{x} e \mathbf{w}_j (Haykin, 1999 pp. 443 - 453). O neurônio particular $i(\mathbf{x})$ que satisfaz esta condição é chamado de neurônio vencedor de melhor correspondência para o vetor de entrada.

Quanto à cooperação, Haykin (1999 pp. 443 - 453) assume uma região topológica centrada no neurônio vencedor, incluindo neurônios cooperantes, normalmente indexados por j . Sendo $d_{i,j}$ a distância lateral entre neurônio vencedor i e neurônio excitado j , então, podemos assumir que a vizinhança topológica é uma função unimodal dessa distância. Esta vizinhança deve ser simétrica em relação ao ponto máximo equivalente à posição do neurônio vencedor para o qual a distância $d_{i,j}$ é zero. A amplitude da mesma deve diminuir monotonicamente com o aumento da distância lateral. Sendo assim, uma distribuição típica de $h_{j,i}$ que satisfaz esses requisitos é a função Gaussiana dada por:

$$h_{j,i(\mathbf{x})}(n) = \exp\left(-\frac{d^2}{2\sigma^2(n)}\right), \quad n = 0,1,2 \dots \quad (18)$$

onde o parâmetro $\sigma(n)$ é a "largura efetiva" da vizinhança topológica em função do tempo discreto. Ele mede o grau em que os neurônios excitados na proximidade do neurônio vencedor participam do processo de aprendizagem. À medida que o número de iterações aumenta, a largura $\sigma(n)$ diminui a uma taxa exponencial, e a vizinhança topológica encolhe de maneira correspondente.

O último processo, denominado de processo adaptativo sináptico, na formação auto-organizada de um mapa de recursos, consiste no ajuste do vetor de pesos sinápticos \mathbf{w}_j do neurônio j (Haykin, 1999 pp. 443 - 453). Dado o vetor de peso sináptico $\mathbf{w}_j(n)$ do neurônio j no tempo discreto n , o vetor de peso atualizado $\mathbf{w}_j(n + 1)$ no tempo $n + 1$ é definido por

$$\mathbf{w}_j(n + 1) = \mathbf{w}_j(n) + \eta(n)h_{i,j(\mathbf{x})}(n) (\mathbf{x} - \mathbf{w}_j(n)) \quad (19)$$

que é aplicado a todos os neurônios na rede que se encontram dentro da vizinhança topológica do neurônio vencedor i , fazendo com que os neurônios que são adjacentes na rede tendam a ter vetores de peso sinápticos semelhantes. $\eta(n)$ corresponde à taxa de aprendizado do algoritmo, que deve decrescer com o passar do tempo.

2.5.2.3 Máquinas de vetor de suporte

Segundo Gu, Andersson e Vicen (2010), ao contrário dos classificadores de redes neurais artificiais que minimizam o erro para o conjunto de treinamento, um classificador SVM é projetado para minimizar o erro de generalização. Além disso, a complexidade de um classificador SVM pode ser controlada e está associada à chamada dimensão do espaço de hipóteses. Uma característica especial de um SVM é que, em vez da redução de dimensão comumente empregada na classificação de padrões, o espaço de entrada é mapeado de forma não linear para um espaço de características com dimensionalidade elevada, através da aplicação de um *kernel*. A razão de usar esse mapeamento é que as classes de recursos são mais propensas a serem separadas linearmente em um espaço dimensional maior em vez de um que possua poucas dimensões.

Uma função de mapeamento não-linear $\Phi(\mathbf{x})$ é aplicada pela primeira vez ao vetor de entrada em um espaço de características de dimensionalidade elevada. Então, outra função é aplicada para mapear o espaço de características de alta dimensionalidade em um espaço de hipóteses (Gu; Andersson; Vicen, 2010). A função

que melhor classificar uma amostra desconhecida de um conjunto de teste é aquela que minimiza o erro de generalização, definido por:

$$R(f) = \int l[f(\Phi(\mathbf{x})), d] dP(\Phi(\mathbf{x}), d) \quad (20)$$

onde $l(.)$ é a função de perda, $f(.)$ a função que mapeia o espaço de características em um espaço de hipóteses e $P(\Phi(\mathbf{x}), d)$ a probabilidade. Para Vapnik e Chervonenkis (1971) sendo $P(\Phi(\mathbf{x}), d)$ desconhecida, não é possível calcular o funcional de risco $R(f)$. Tornando-se assim necessário recorrer a uma estimativa obtida dos dados de treinamento, ou seja, ao funcional de risco empírico. Se $R_{emp}(f)$ converge uniformemente em probabilidade para $R(f)$, então supõe-se que a minimização de $R_{emp}(f)$ vai fornecer o mínimo de $R(f)$. A teoria de convergência uniforme em probabilidade também proporciona um limitante para a variação do risco esperado $R(f)$ em função do risco empírico $R_{emp}(f)$, que acontece com probabilidade $1 - \delta$:

$$R(f) \leq R_{emp}(f) + \sqrt{\frac{h \left(\ln \left(\frac{2N}{h} \right) + 1 \right) - \ln \left(\frac{\delta}{4} \right)}{N}} \quad (21)$$

onde

$$R_{emp}(f) = \frac{1}{N} \sum_{i=1}^N l[f(\Phi(\mathbf{x}_i)), d_i] \quad (22)$$

e h é dimensão do espaço de hipóteses. Para um dado número de amostras de treinamento, há um valor ótimo para h . A técnica de minimização do risco estrutural (*Structural Risk Minimization* - SRM), é uma tentativa de tratamento para o problema da escolha da dimensionalidade apropriada o qual é utilizado para determinar $f(.)$ de tal forma que resulte no erro mínimo (Vapnik, 1995).

Em termos aproximados, uma solução ótima para um classificador SVM está associada à maximização das margens ($\alpha / \|\mathbf{w}\|^2$). Uma margem é a distância mais curta entre o limite de separação e uma amostra de treinamento corretamente classificada. Esta, por sua vez, seria a mais próxima do limite de separação. Gu, Andersson e Vicen (2010) implementam um SVM para classificar quatro tipos

diferentes de nós de madeira, incluindo nós *sound* e *rotten*. Utilizou-se um C-SVM, também chamado de tipo 1, que busca a minimização da seguinte forma

$$\min_{\mathbf{w}, b, \xi} \left(\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i \right) \quad (23)$$

onde C é um parâmetro de regularização determinado empiricamente, \mathbf{w} é o vetor de coeficientes e ξ_i representa parâmetros para manipulação de dados de entradas. O índice i rotula os casos de treino N . Finalmente, a função de decisão para o classificador SVM implementado é

$$f(\mathbf{x}) = \text{sgn} \left(\sum_{i=1}^{N_s} \alpha_i d_i k(\mathbf{x}, \mathbf{x}_i) + b \right) \quad (24)$$

onde N é o número de vetores de suporte \mathbf{x}_i , obtidos através dos dados de treinamento. Segundo os autores, o classificador foi treinado usando 800 imagens de nós de madeira da Suécia e 400 imagens foram utilizadas para teste, atingindo uma acurácia de 96%. Hittaweia et al. (2015) aplicam o mesmo classificador à uma base com 100 amostras para teste e obtém acurácia de 92%.

3 IMPLEMENTAÇÃO DO SISTEMA DE DETECÇÃO DE NÓS

Este trabalho consiste no desenvolvimento de um sistema para inspeção de nós em placas de madeira serrada. Esta seção refere-se à arquitetura do sistema desenvolvido. Também são descritos os diferentes métodos utilizados como forma de comparação de sua eficiência no reconhecimento dos defeitos para a base de dados concebida. Da mesma forma, são apresentados os métodos de avaliação a serem aplicados para medir o desempenho do classificador.

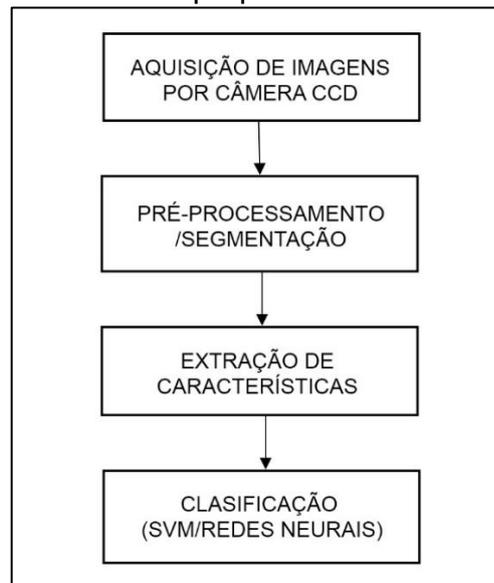
3.1 ARQUITETURA DO SISTEMA

A fim de detectar e classificar os nós de madeira, este trabalho propõe a utilização de uma câmera para capturar imagens pelas quais o sistema realiza todo o processamento. As informações da localização e do tipo de nó podem ser então passadas para o sistema de manufatura a fim de que tome as ações necessárias para o melhor aproveitamento da madeira.

A arquitetura do sistema proposto pode ser dividida em 5 etapas, conforme é apresentada na Figura 5:

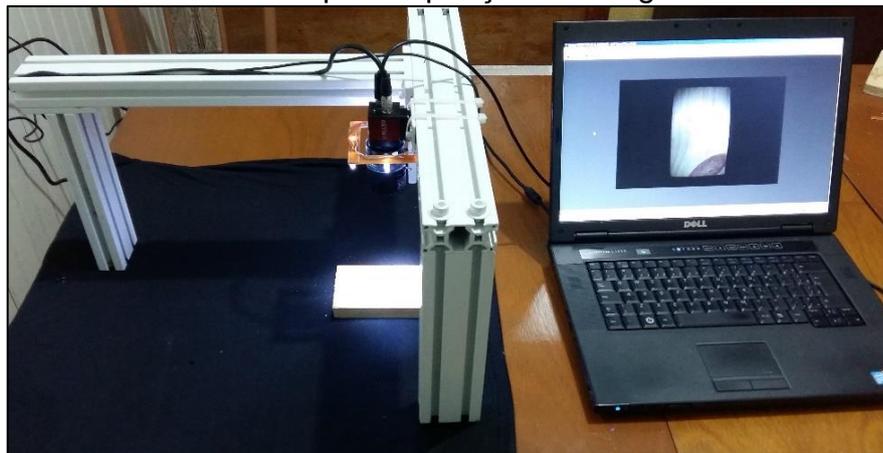
1. **Aquisição de Imagens por Câmera CCD:** foi utilizada a câmera de visão de máquina Guppy F-038C NIR, lente e iluminação auxiliar construída com diodos emissores de luz (*Light Emitting Diode* – LED) de luz branca. A câmera permite uma aquisição de até 30 quadros por segundo; possui sensor CCD Sony ICX428AKL com microlentes para maior sensibilidade à faixa de frequências próximas à luz do infravermelho (NIR); pode captar imagens de até 768x492 pixels; possui interface digital IEEE 1394a (*Firewire*) (Allied Vision Technologies GmbH, 2015). Esta câmera foi escolhida devido à proximidade das especificações técnicas encontradas na bibliografia (Li, et al., 2017) e também devido à disponibilização da mesma pela Universidade de Caxias do Sul. A câmera CCD foi posicionada acima das amostras de madeiras para a captura de imagens. Uma estrutura metálica foi utilizada para suspender o dispositivo CCD e os LEDs para a iluminação. A bancada de testes como um todo pode ser observada na Figura 6. A Figura 7 mostra uma imagem adquirida de uma placa de madeira contendo nós para teste.

Figura 5 – Diagrama de blocos do sistema para classificação de nós de madeira proposto.



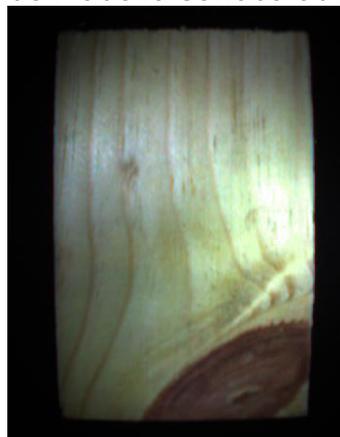
Fonte: o autor (2017).

Figura 6 – Bancada de testes para aquisição de imagens de madeira serrada.



Fonte: o autor (2017).

Figura 7 – Imagem de madeira serrada adquirida pelo sistema.



Fonte: o autor (2017).

2. **Segmentação:** esta etapa tem como principal função segmentar as regiões contendo nós e reduzir interferências geradas por ruído. Para tanto, foi feito um comparativo entre os métodos de detecção de bordas por filtros Gabor e outro de reconstrução morfológica proposto por Zhang et al. (2014). Este último tem como primeiro passo a extração de um “esqueleto” do nó a ser classificado a partir do processo de erosão matemática. Assume-se então que existe um objeto binário, considerando o pixel da região do objeto como 1 e o pixel do fundo como 0, a partir de um limiar do nível de cinza da imagem. Faz-se uma análise de vizinhos a partir de um pixel central. Em seguida, realiza-se a reconstrução morfológica baseada em uma expansão matemática denominada como geodésica, que é controlada por outra imagem binária, por intersecção, retirada do componente R da imagem original.
3. **Extração de Características:** nesta etapa, foram extraídas características referentes à cor, textura e estatística. Como forma de extração das informações acerca de cores, foram calculadas a média e a variância. Em relação às texturas, foram utilizadas LBP, GLCM e filtros *Gabor*.
4. **Classificação:** nesta etapa, as características obtidas no processo anterior foram utilizadas para a classificação dos diferentes tipos de nó através da implementação de redes neurais e SVM. Com o objetivo de redução de dimensionalidade e seleção de características a fim de aprimorar o processo de classificação, também foi aplicado o LDA visando à otimização da implementação de redes neurais. Tratando-se deste classificador, aplicou-se o tipo supervisionado (MLP). Em alternativa, utilizou-se o SVM também como método de reconhecimento.

3.2 BASE DE DADOS

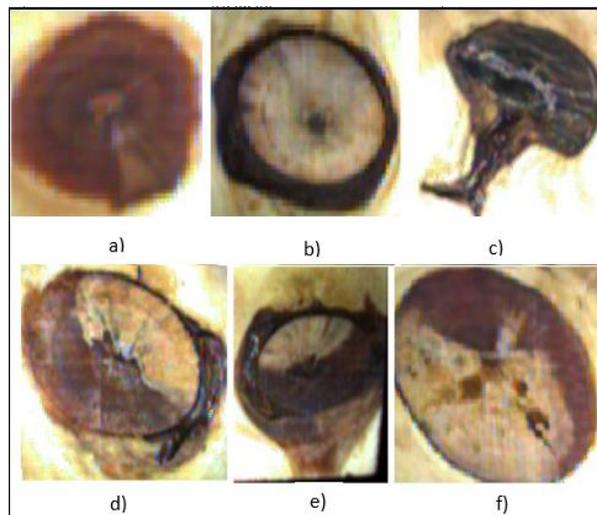
Como o problema possui características da empresa local, uma base de dados foi criada para estimar os modelos e avaliar a solução. A base foi composta por imagens de madeira serrada obtidas a partir de árvores da espécie *Pinus elliotti*. As peças em questão foram apenas disponibilizadas em pedaços para o desenvolvimento do trabalho com dimensões de até 100 mm de largura por até 200

mm de comprimento e 20 mm de espessura. A resolução a ser utilizada pela câmera de CCD é 768x492 pixels.

A disposição da câmera para a coleta foi feita conforme a Figura 6. A câmera foi posicionada em armação de alumínio a aproximadamente 18 cm da madeira. A lente a ser utilizada é do tipo varifocal com comprimento focal de 4 a 12 mm, íris manual e correção de infravermelho. Os LEDs para a iluminação foram montados em um suporte em formato quadrangular preso em volta da câmera e possuem 5mm de diâmetro e 20000mcd. As imagens foram coletadas de seções de madeira colocadas abaixo da câmera CCD.

As imagens foram rotuladas manualmente com o tipo de nó presente, a localização do ponto central de cada nó e as coordenadas dos limites em x e y, indicados em pixels. São considerados então apenas os nós descritos pela bibliografia para que seja realizada a classificação. Conforme Gu, et al (2010), foram descritos nós do tipo *sound* como aqueles que poderiam ter o formato externo elíptico com cores levemente escuras com tonalidade avermelhada e texturas diferentes em comparação com a madeira de fundo, como pode ser observado na Figura 8a. O tipo *dead*, aqueles que possuíam uma borda escura, com a parte interna ligeiramente mais escura que a madeira limpa (Figura 8b). Nós com a região interna escura, com ou sem uma borda externa também escura foram considerados como *rotten*, conforme a Figura 8c. No entanto, haviam algumas amostras que se encontravam em estados intermediários, conforme as Figura 8d, 8e e 8f , o que dificulta a classificação mesmo que manual.

Figura 8 – Imagens de diferentes tipos de nós adquiridas pelo sistema. a) Sadio. b) Morto. c) Podre. d), e) e f): Não classificado.



Fonte: o autor (2018).

Inicialmente, foram coletadas 1000 imagens de madeira, sendo 900 com a presença de nós e 100 que não possuíam nós. Como algumas imagens possuíam mais de um nó por imagem, o total capturado foi de 918. Os tipos de nós presentes nas amostras são do tipo saudável, morto, podre e não identificado, como mostra a Tabela 1.

Tabela 1 – Número de amostras por tipo de nó

Tipo	Quantidade de Amostras
Saudáveis	303
Mortos	219
Podres	185
Indefinidos	211
Total	918

Fonte: O autor.

3.3 SEGMENTAÇÃO

Foram implementados dois métodos para a segmentação. O primeiro método é baseado na análise de textura por filtros Gabor e o segundo, em níveis da escala de cinza, utiliza a reconstrução morfológica.

3.3.1 Método por filtros Gabor

Conforme o método proposto por Jain, et al (1990), uma forma de fazer a segmentação de imagens pelos padrões de textura, é pelos filtros Gabor. A imagem original é decomposta em várias imagens filtradas com informações espectrais limitadas. É utilizando um banco de filtros Gabor bidimensionais que consistem de uma onda plana senoidal de alguma frequência e orientação, modulada por um envelope Gaussiano. Um filtro Gabor canônico no domínio espacial é dado por

$$h(x, y) = \exp \left\{ -\frac{1}{2} \left[\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2} \right] \right\} \cos(2\pi u_0 + \phi) \quad (25)$$

onde u_0 e ϕ são a frequência e fase da onda plana senoidal ao longo do eixo x e σ_x e σ_y são as constantes espaciais do envelope gaussiano ao longo dos eixos x e y,

respectivamente. As propriedades seletivas de frequência e orientação de um filtro Gabor são mais explícitas em sua representação no domínio da frequência. Com $\varnothing = 0$, a transformada de Fourier da função Gabor é dada por

$$H(u, v) = A \left(\exp \left\{ -\frac{1}{2} \left[\frac{(u - u_0)^2}{\sigma_u^2} + \frac{v^2}{\sigma_v^2} \right] \right\} + \exp \left\{ -\frac{1}{2} \left[\frac{(u + u_0)^2}{\sigma_u^2} + \frac{v^2}{\sigma_v^2} \right] \right\} \right) \quad (26)$$

onde $\sigma_u = \frac{1}{2} \pi \sigma_x$, $\sigma_v = \frac{1}{2} \pi \sigma_y$ e $A = 2 \pi \sigma_x \sigma_y$. A representação do domínio de Fourier especifica o valor pelo qual o filtro modifica ou modula cada componente de frequência da imagem de entrada. Tais representações são, portanto, referidas como funções de transferência de modulação (FTM). No referido trabalho, são utilizados quatro valores de orientação: 0° , 45° , 90° e 135° . Para uma imagem com uma largura de N_c pixels, onde N_c é um valor determinado a partir de uma potência de 2, os seguintes valores de frequência radial u_0 são usados: $1\sqrt{2}$, $2\sqrt{2}$, $4\sqrt{2}$, ... , e $(\frac{N_c}{4})\sqrt{2}$ ciclos/largura da imagem. Para reduzir o número de características de textura, é utilizado apenas um subconjunto das imagens filtradas, que possuam as características mais relevantes. Para tanto, busca-se um subconjunto de apenas algumas imagens filtradas $\hat{s}(x, y)$ que se aproxime da reconstrução obtida pela junção de todas as imagens filtradas $s(x, y)$. O erro envolvido no uso de $\hat{s}(x, y)$ em vez de $s(x, y)$ pode ser calculado por:

$$SSE = \sum_{x,y} [\hat{s}(x, y) - s(x, y)]^2 \quad (27)$$

Cada imagem filtrada é submetida a uma transformação não linear dada por:

$$\psi(t) = \tanh(\alpha t) = \frac{1 - e^{-2\alpha t}}{1 + e^{-2\alpha t}} \quad (28)$$

O desvio absoluto médio (AAD) da média dos atributos é então calculado em pequenas janelas sobrepostas. Formalmente, a imagem de características $e_k(x, y)$ correspondente à imagem filtrada é dada por:

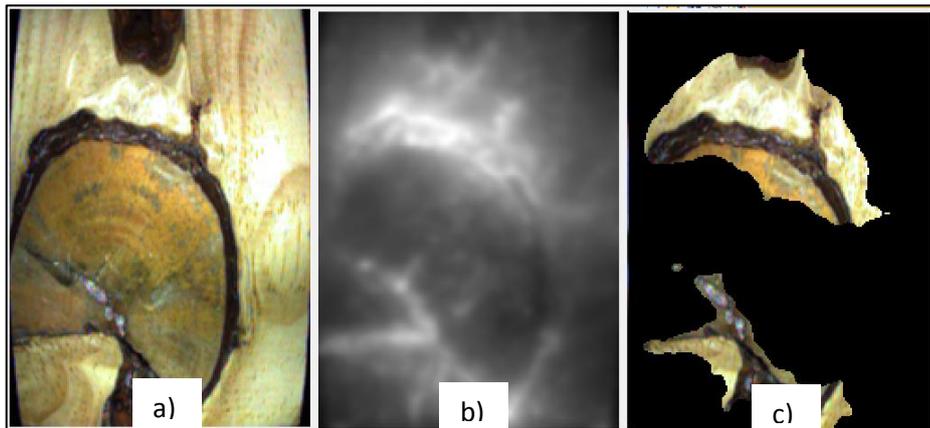
$$e_k(x, y) = \frac{1}{M^2} \sum_{(a,b) \in W_{xy}} |\psi(r_k(a, b))| \quad (29)$$

onde W_{xy} é uma janela $M \times M$ pixels centrada no pixels com coordenadas (x, y) . Tendo obtido as imagens de características, faz-se então clusterização do espaço de

características, agrupando as características capazes de representar diferentes classes de texturas.

No presente trabalho, utilizou-se a Análise de Componente Principal para desempenhar esta função e determinar qual das características que apresentavam as maiores variâncias possíveis e pudessem representar as diferentes texturas da imagem. Além disso, para o agrupamento das janelas com características semelhantes, visando à segmentação utilizou-se o algoritmo *k-means*. O resultado da segmentação por esse método pode ser visto na Figura 9c. É possível visualizar na Figura 9b que a variância entre as características obtidas na região externa e interna do nó, não foi suficiente para executar a segmentação corretamente. Isso porque a textura da região interna do nó é semelhante à textura da madeira limpa. Dessa forma, esse não é um método adequada para a aplicação.

Figura 9 – Resultado obtido na segmentação por filtros Gabor. a) Imagem original. b) Variância das características no espaço de características. c) Segmentação obtida.



Fonte: o autor (2018).

3.3.2 Método de reconstrução morfológica

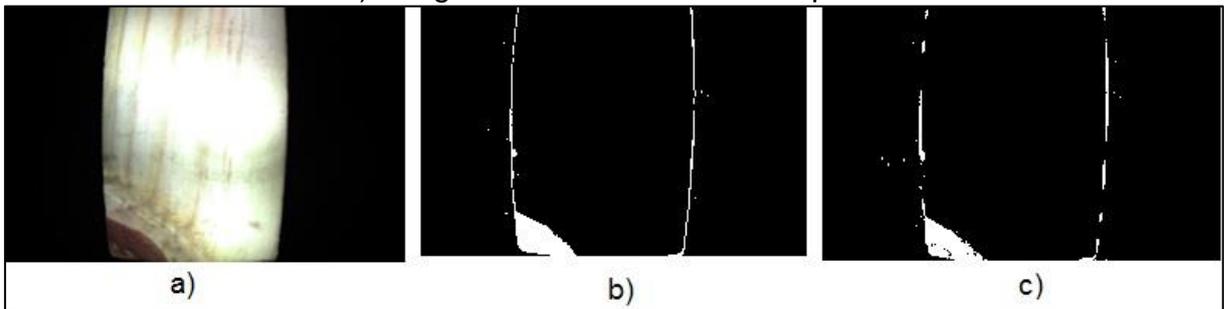
Uma forma de implementar a segmentação de nós de madeira é utilizando reconstrução morfológica. Para isso, Zhang, et al (2014) sugerem os seguintes passos:

1. Extração da componente R das imagens;
2. Binarização da imagem;
3. Extração do esqueleto (operação morfológica);
4. Operação de poda;
5. Definição do limitante de crescimento;

6. Reconstrução morfológica;
7. Preenchimento;
8. Suavização de bordas.

Devido a alguns testes executados para a base de dados construída, verificou-se que os contornos das regiões da imagem binária ficaram mais definidos para a imagem em escala de cinza do que para a componente R. Por conta disso, optou-se pela imagem em tons de cinza para aplicar a segmentação. O comparativo pode ser visto na Figura 10. Em seguida, aplica-se uma erosão matemática para eliminar detalhes pequenos indesejados.

Figura 10 – Binarização da imagem. a) Imagem original de madeira contendo o nó. b) Imagem binária obtida a partir da transformação da imagem original em tons de cinza. c) Imagem binária obtida da componente R.



Fonte: o autor (2018).

Conforme, Zhang, et al (2014) faz-se então a extração do esqueleto da imagem binária (Figura 12b), que pode ser expressa por

$$S(A) = \bigcup_{k=0}^K S_k(A) \quad (30)$$

$$S_k(A) = (A \ominus kB) - (A \ominus kB) \circ B \quad (31)$$

onde A é o alvo, B é o elemento estruturante e $(A \ominus kB)$ é a operação de erosão de k multiplicado por A . O k é a última interação da operação antes de A se tornar um conjunto vazio. Os pixels possuem valor “1” e pelo menos um pixel vizinho com valor “0” são considerados como componentes da margem do objeto e, portanto, são eliminados a cada interação da erosão. A operação de “poda” (Figura 12c) é então executada para eliminar elementos pequenos não pertencentes ao esqueleto principal. Os pixels que satisfazem a seguinte condição são apagados:

$$\begin{bmatrix} p_9 & p_2 & p_3 \\ p_8 & p_1 & p_4 \\ p_7 & p_6 & p_5 \end{bmatrix} \begin{cases} N(p_1) < 4 \\ T(p_1)_1 = 1 \\ T(p_1)_2 = 1 \end{cases} \quad (32)$$

com $N(p_1)$ igual ao número de vizinhos não nulos, $T(p_1)_1$ é o número de mudanças de 0 para 1 na sequência $p_2, p_3, p_4, p_5, p_6, p_7, p_8, p_9$ e p_2 e $T(p_1)_2$ se refere às mudanças de 1 para 0 na mesma sequência.

Segundo Zhang, et al (2014), a reconstrução morfológica utiliza a expansão geodésica e tem F como uma imagem semente, que neste caso será o esqueleto, e G como uma imagem que define os limites de crescimento, e assumindo que ambas as imagens são binárias e $F \subseteq G$, tem-se a expansão geodésica do modelo com o valor de 1 sobre a imagem semente:

$$D_G^{(1)}(F) = (F \oplus B) \cap G \quad (33)$$

Para a implementação de todas as operações morfológicas na imagem binária, é utilizado um *toolbox* de processamento de imagem, disponibilizado pelo software Matlab (Mathworks). Com isso, através da utilização da função *bwmorph* são possíveis as operações de erosão, dilatação, extração de esqueleto, reconstrução e preenchimento. A Figura 11 mostra uma parcela do código fonte adaptado para exibir alguns exemplos de funções morfológicas utilizadas através de *toolbox*. Lembrando que várias outras etapas da segmentação foram desenvolvidas sem o auxílio de funções prontas, conforme pode ser observado no Apêndice A.

Figura 11 – Exemplos de operações morfológicas implementadas com a utilização do toolbox de processamento de imagem disponibilizado pelo software Matlab.

```
%encontra o esqueleto do nó |
BW3 = bwmorph(imagem_binaria, 'skel', Inf);

%operação de reconstrução morfológica utilizando o esqueleto como
%imagem semente
im = imreconstruct(BW3, imagem_binaria);

%preenchimento morfológico dos "furos" da imagem
I2 = imfill(im, 'holes');

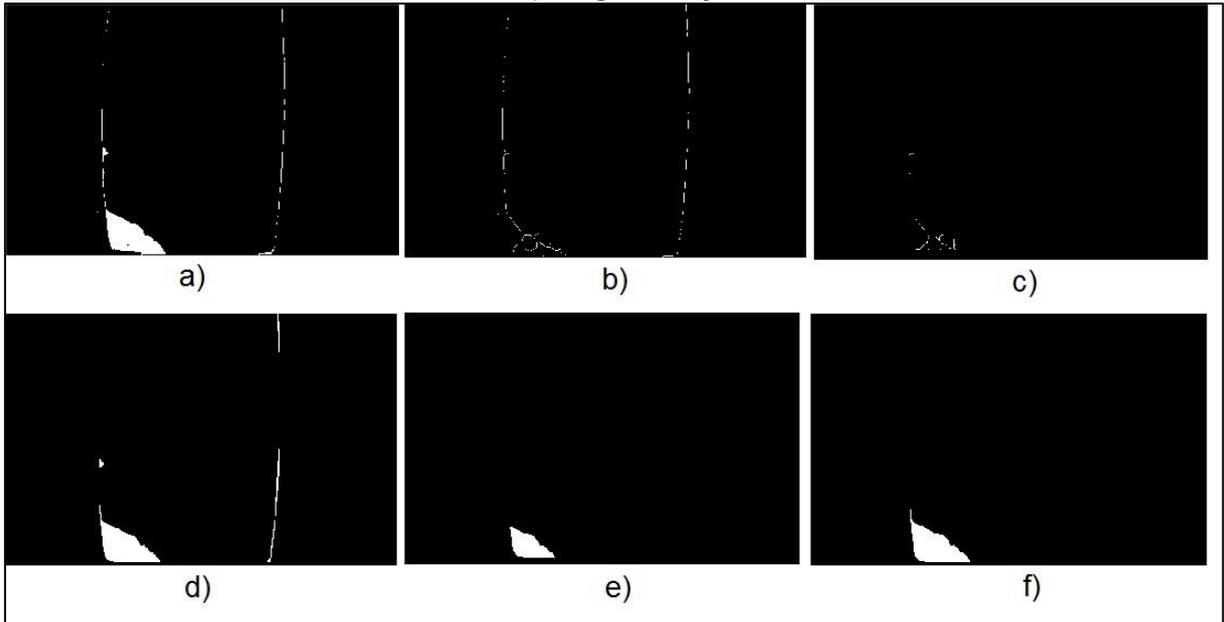
%erosão matemática para eliminar segmentos indesejados
se = strel('disk', 1, 8); %definindo elemento estruturante
erodedBW = imerode(I2, se);

%dilatação morfológica para repor pixels retirados pela erosão
se = strel('disk', 2, 8); %definindo elemento estruturante
BW2 = imdilate(BW1result, se);
```

Fonte: o autor (2018).

A Reconstrução morfológica e preenchimento de furos obtidas são mostradas na Figura 12d. Em seguida, faz-se a segunda etapa de erosão (Figura 12e) e a reconstrução novamente (Figura 12f).

Figura 11 – Operações morfológicas. a) Binarização. b) Extração do esqueleto. c) Operação de poda. d) Reconstrução e preenchimento de furos. e) Segunda etapa de erosão. f) Segmentação obtida.



Fonte: o autor (2018).

3.4 EXTRAÇÃO DE CARACTERÍSTICAS

Visando à classificação das amostras, fez-se a extração das características a partir das informações de cores das camadas do RGB, texturas através da utilização de LBP, GLCM e filtros *Gabor*.

A fim de capturar as características das cores, estatísticas das camadas do RGB foram utilizadas como características. Foram aplicadas as médias das três camadas da imagem, bem como a variância e o quarto momento estatístico para cada uma das três camadas, totalizando 9 características de cores. O quarto momento é relacionado com a curtose, que é uma medida relativa do “pico” ou da planicidade de uma distribuição (Vetterling, et al., 2002).

As características de texturas puderam ser geradas através de histogramas obtidos pelo LBP e estatísticas do GLCM. Primeiramente foram obtidos vetores de características com 10 dimensões através de *Local Binary Patterns*. Isto porque, como as informações de textura invariante de rotação descritas por Ojala, Pietikäinen e Mäenpää (2002), não são relevantes na classificação de nós, da base constituída,

foram utilizadas apenas as características referentes à vizinhança. Considerando 8 vizinhos por janela, têm-se a dimensionalidade descrita por $D = P + 2$, com P sendo o número de vizinhos. Além disso, faz-se a extração de 14 características estatísticas obtidas através da GLCM, conforme proposto e detalhado por Haralick, Shanmugam e Dinstein (1973) também para análise de texturas: autocorrelação, contraste, correlação, soma de quadrados: variância, soma das médias, soma das variâncias e soma das entropias. Além disso, destas características, são calculadas: proeminência de *cluster*, sombra de *cluster*, dissimilaridade, energia, homogeneidade e probabilidade máxima apresentadas por Soh e Tsatsoulis (1999) para o mesmo fim. Para que fossem escolhidas estas características, foram feitos testes utilizando apenas as características do trabalho de Soh e Tsatsoulis (1999) e também para todas as *features* citadas anteriormente da GLCM. Obteve-se assim acurácias de 92% e 95,7% respectivamente na classificação com as mesmas amostras, atingindo 14 características dispostas em vetores de duas posições, resultando em um vetor de 28 dimensões.

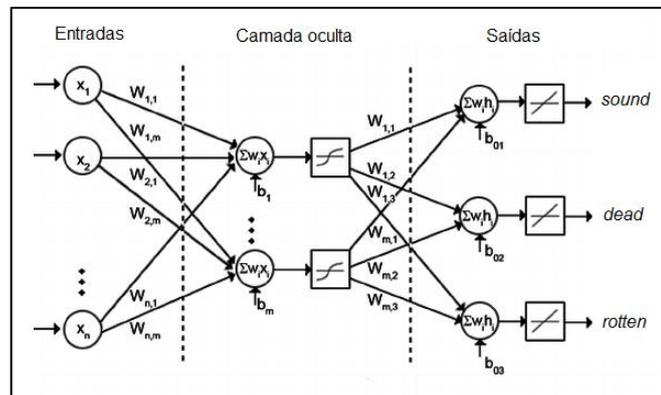
Um banco de filtros Gabor composto por 36 filtros foi implementado, normalizando-se as imagens para 32x32 pixels, como descrito por Marcano-Cedeño, Quintanilla-Domínguez e Andina (2009) para classificação de defeitos de madeira. Como são utilizados 36 filtros, com imagens de 32x32 pixels, obtém-se um total de 36864 *features*. No entanto, segundo Haghghat, Zonouz e Abdel-Mottaleb (2015) como os pixels adjacentes em uma imagem são geralmente, altamente correlacionados, pode-se reduzir essa redundância de informações diminuindo a resolução das imagens de características resultantes dos filtros Gabor. Neste caso, como sugerido pelos autores, as imagens de características foram reduzidas por um fator de amostragem de quatro, ou seja, o vetor de características resultante tem dimensionalidade $36864/(4 \times 4) = 2304$. Estes vetores são então, normalizados para média 0 e variância unitária. Para o caso onde foram extraídas as características Gabor, aplicou-se a análise de discriminante linear visando à redução do espaço de características, conseguindo assim um vetor com uma dimensionalidade relativamente menor, de 311 características.

O vetor composto por todas as características extraídas foi composto por 2351 dimensões. Com a redução provida pela análise de discriminante linear, foi possível obter um vetor de 283 características.

3.5 CLASSIFICAÇÃO

Uma rede neural MLP com 3 neurônios na camada de saída é utilizada como classificador, conforme arquitetura mostrada na Figura 13. A função de ativação das camadas de entrada e oculta é a tangente hiperbólica, enquanto que da camada oculta para a saída, tem-se softmax. O algoritmo utilizado para o treinamento foi o de *Bayesian regularization backpropagation*, baseado na aproximação de Levenberg-Marquardt o qual foi implementado por YongHua et al. (2015) para reconhecimento de nós de madeira.

Figura 13 – Arquitetura da rede neural MLP implementada para classificação de nós.



Fonte: Adaptado de Lugado, et al. (2014).

Como o SVM é um classificador binário, o reconhecimento também foi realizado utilizando uma hierarquia de SVM, conforme ilustrado na Figura 14. O primeiro SVM faz a classificação entre os nós do tipo *sound* em relação ao restante. As amostras que não foram classificadas como o tipo *sound* são então classificadas pela segunda SVM entre o tipo *dead* e o *rotten*. As SVM utilizaram o *kernel* implementado por Gu, et al (2010), gaussiano, expresso como

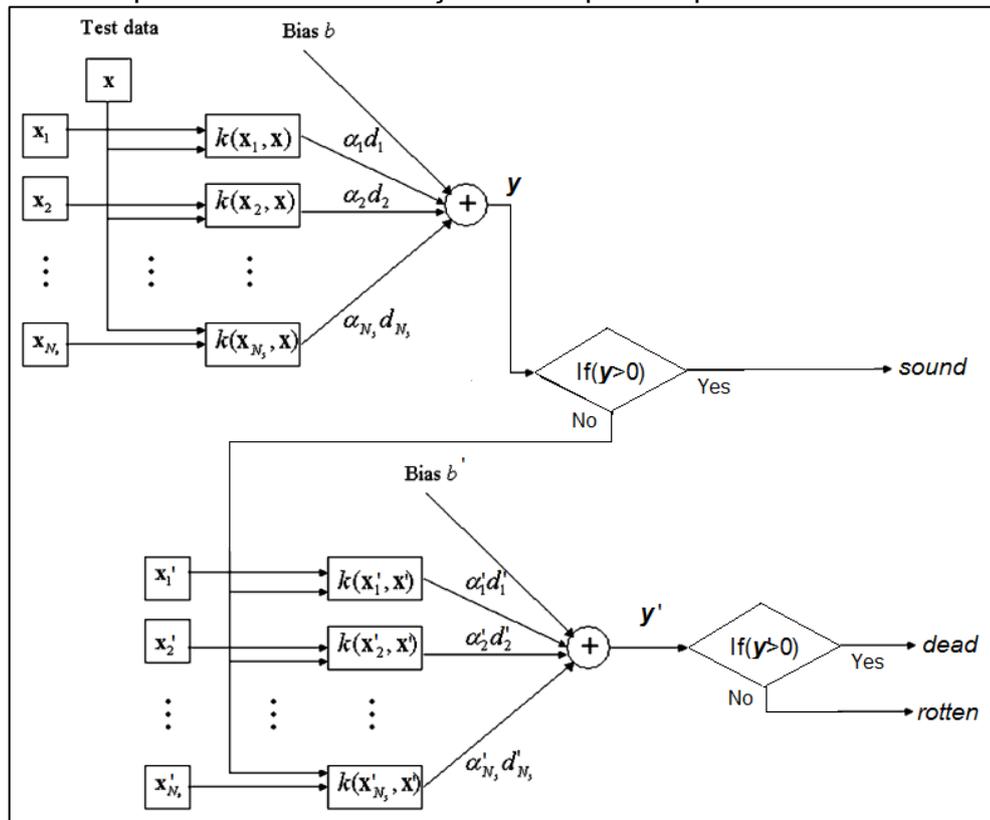
$$G(x_j, x_k) = \exp\left(-\|x_j - x_k\|^2\right) \quad (34)$$

sendo x_j e x_k vetores representando observações j e k do vetor de características. Uma forma alternativa de *kernel* também aplicado é o polinomial, dado por

$$G(x_j, x_k) = (1 + x_j'x_k)^3. \quad (35)$$

A validação cruzada foi feita pelo método *leave one out*.

Figura 14 – Arquitetura da classificação hierárquica implementada com dois SVM.



Fonte: Adaptado de Gu (2009).

3.6 MÉTODO DE AVALIAÇÃO

Um sistema de identificação e classificação de nós pode ser avaliado utilizando diversas medidas de desempenho, pois diferentes tarefas são realizadas a fim de poder classificar o nó. A primeira tarefa é detectar a existência de um nó. A segunda tarefa é determinar a localização do nó. Finalmente a terceira tarefa é classificar o tipo de nó encontrado. Sendo que os erros em cada tarefa afetam a qualidade do sistema como um todo.

Como a identificação de nós pode ser tratada como um problema de detecção, o resultado do método pode ser avaliado utilizando uma matriz de confusão, como mostrado na Tabela 2. Desta forma, na detecção de nós por imagem, TP corresponde às imagens que continham nós e que foram detectadas corretamente. FN, por sua vez, são amostras que continham nós, mas que não foram corretamente detectadas, FP corresponde aos alarmes positivos, de imagens que não continham nós, mas que acabaram sendo detectadas incorretamente. Por fim, tem-se TN que são as amostras que não continham nós e que não tiveram nós detectados.

Para a detecção por número de nós, o TP são as amostras que continham um número x de nós e tiveram esta mesma quantidade de nós detectada. Os FN por sua vez, são as imagens que continham um número x destes defeitos, onde não foi contabilizada a mesma quantidade de nós detectados. Os FP são amostras com um número diferente de x de nós que tenham sido considerados pelo sistema com esta quantidade. O TN corresponde ao restante das amostras. Estas medidas são efetuadas a partir de uma classe contra a generalização das outras duas (classe das amostras que possuem apenas um nó contra o restante, por exemplo).

Por fim, a matriz de confusão também é utilizada para medir o desempenho na classificação: TP são amostras pertencentes a uma dada classe i classificadas corretamente. FN correspondem às imagens de nós pertencentes à classe i , porém que tenham sido incorretamente classificadas como pertencentes a outras classes. Os FP são amostras não pertencentes à classe i , incorretamente classificadas como tal. FN, por sua vez, corresponde ao restante das imagens.

Tabela 2 – Matriz de confusão para o problema de detecção de nós

		Verdade	
		Com nó	Sem nó
Estimado	Com nó	Positivo Verdadeiro - TP	Positivo Falso – FP
	Sem nó	Negativo Falso - FN	Negativo Verdadeiro – TN

Fonte: O autor.

Para medir o desempenho do sistema como um todo, é calculada a raiz do erro quadrático médio (*Root Mean Squared Error* – RMSE) referente à localização dos pontos centrais dos nós a serem classificados, em relação às imagens rotuladas manualmente. Posteriormente, então, são determinados valores de *recall*, precisão, taxa de falso negativo (*False Negative Rate* – FNR) e acurácia para medir o desempenho da classificação por tipo de nó.

Segundo Chai e Draxler (2014), a raiz do erro quadrático médio (*Root Mean Square Error* - RMSE) ajuda a fornecer uma imagem completa confiável da distribuição de erros, a qual segue uma distribuição Gaussiana. Pela definição, têm-

se a equação do RMSE adaptado para cálculo do erro de localização dos centroides dos nós da seguinte maneira

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N \frac{((x_i - x'_i)^2 + (y_i - y'_i)^2)}{2}} \quad (36)$$

onde N é o número total de imagens existentes na base de dados de teste, x_i e y_i são as localizações das coordenadas x e y do centroide do nó rotulado manualmente na imagem i e x'_i e y'_i são as coordenadas encontradas pelo classificador para a mesma imagem, em pixels.

Conforme, Hittaweia, et al (2015), o recall (ou taxa positiva real) dá a proporção de defeitos reais corretamente identificados e é definido como:

$$Recall = \frac{TP}{(TP + FN)} \quad (37)$$

A precisão dá a proporção de casos identificados de forma positiva que são defeitos reais e é dada por

$$Precisão = \frac{TP}{TP + FP} \quad (38)$$

A taxa de falso negativo (FNR) representa a proporção de defeitos reais que não são detectados e é dada por

$$FNR = \frac{FN}{(FN + TP)} \quad (39)$$

Por fim, YongHua e Jin-Cong (2015) definem a acurácia como correspondente à taxa de amostras positivas e negativas classificadas corretamente, dada por

$$Acurácia = \frac{\text{Amostras corretamente classificadas}}{\text{Total de amostras para teste}} \times 100\% \quad (40)$$

3.7 RESULTADOS

Nesta seção serão apresentados os resultados obtidos. Primeiramente será exibido o método de segmentação implementado nas imagens da base de dados e suas considerações. Em seguida, os testes executados com diferentes características em uma rede neural MLP, além de uma arquitetura contendo SVMs.

3.7.1 Resultados da detecção de nós

Aplicando o método de reconstrução morfológica proposto por (Zhang, et al., 2014), na base de dados constituída por 1000 imagens de madeira serrada, onde 100 delas não continham nós, buscou-se a segmentação de regiões que continham os nós. A detecção dos mesmos faz-se então anteriormente à reconstrução morfológica, uma vez que os elementos não pertencentes às regiões dos defeitos são anulados pela operação de erosão. Logo, os elementos restantes não eliminados por esta operação matemáticas, pertencem às áreas do nó. O algoritmo obteve uma acurácia de 94,4%, recall de 94,6%, precisão de 99,2% e FNR igual a 5,4%. A Tabela 3 mostra a matriz de confusão obtida para a detecção de nós.

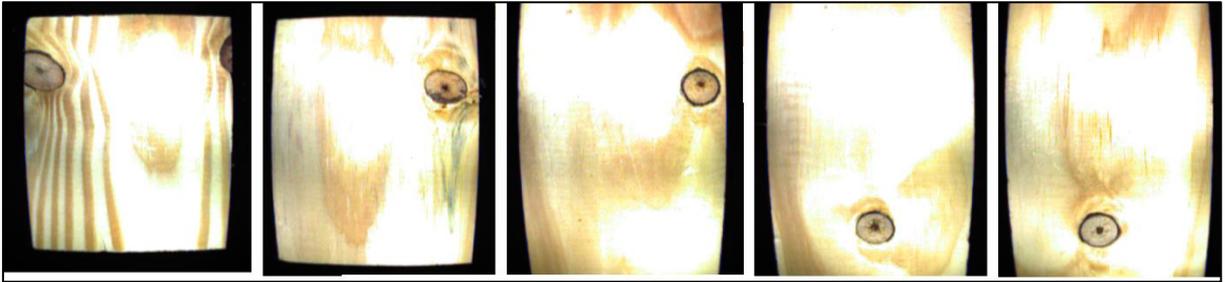
Tabela 3 – Matriz de confusão da detecção de nós

		Verdade	
		Com nó	Sem nó
Estimado	Com nó	851	49
	Sem nó	7	93

Fonte: O autor.

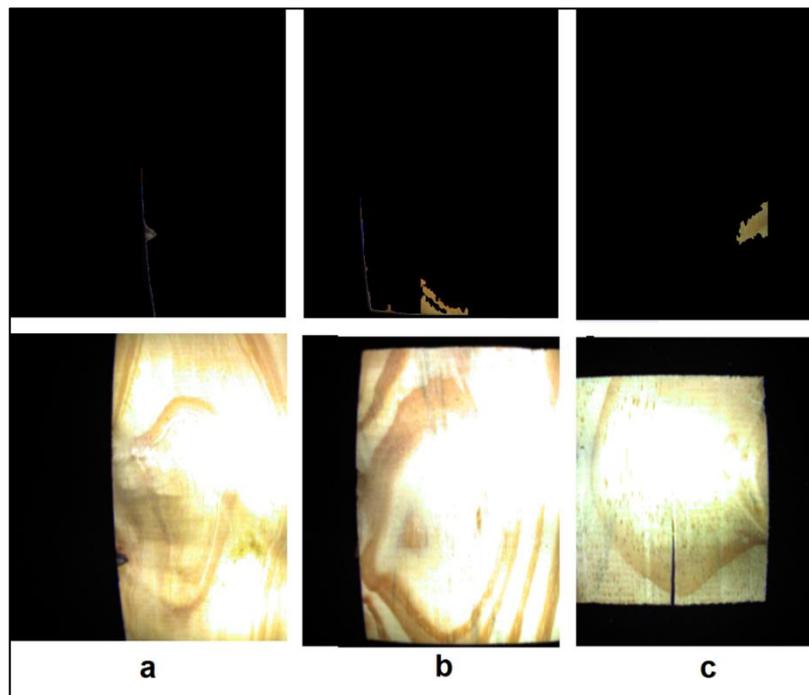
Como se pode observar, houve 49 falsos negativos durante a classificação. Isso se deve principalmente pela presença de nós do tipo *dead* de tamanho reduzido com a região interna clara e borda externa escura inexistente ou pouco espessa, como pode ser visto na Figura 15. Os falsos alarmes gerados têm como fonte a existência de defeitos não classificados como nós (Figura 16a), ou então regiões de madeira “limpa” escuras (Figura 16b), ou ainda a não homogeneidade da iluminação auxiliar do sistema (Figura 16c), o que acaba gerando áreas escuras devido à falta de luz.

Figura 15 – Nós não detectados pelo sistema.



Fonte: O autor.

Figura 16 – Falsos alarmes gerados na detecção.



Fonte: O autor.

Após a detecção das imagens que continham nós, fez-se então a reconstrução morfológica, localização e contabilização dos mesmos. Para isso, executa-se uma varredura pela imagem reconstruída buscando o primeiro pixel não nulo, a partir de $x = 0$ e $y = 0$. Feito isso, caso a imagem contenha pixels não nulos, determina-se os pontos de x e y de início de uma área que contenha um nó. Em seguida, são determinados os pontos finais da região do nó, concebendo-se uma forma retangular não nula sobreposta a uma imagem nas mesmas dimensões da imagem adquirida da madeira originalmente. Após a região do primeiro nó ser definida, buscam-se outros nós presentes na imagem reconstruída. Por fim, cada nó é adicionado a uma linha de uma matriz $R = [r_{ij}]_{m \times n}$, onde m corresponde ao número de nós detectados ao final

do processo de segmentação e n é dado pelas informações de localização: r_{i1} corresponde ao número da imagem em questão, r_{i2} ao centroide, calculado pela média dos pontos máximos e mínimos do nó, em x , r_{i3} ao centroide em y , e r_{i4} , r_{i5} , r_{i6} e r_{i7} aos pontos máximos e mínimos em x e y . Após o preenchimento da matriz, realiza-se uma comparação dos nós encontrados com um arquivo denominado alvo, que é outra matriz onde as informações da rotulação manual são armazenadas. O alvo pode ser definido como $A = [a_{ij}]_{m \times n}$, com a_{i1} indicando o número da imagem rotulada, a_{i2} sendo a posição do centroide em x definida manualmente e a_{i3} , em y . Portanto, um nó é definido como corretamente localizado quando cumpre com as Equações 25 e 26.

$$a_{i1} = r_{i1} \quad (41)$$

$$r_{i4} < a_{i2} < r_{i5} \quad (42)$$

$$r_{i6} < a_{i3} < r_{i7} \quad (43)$$

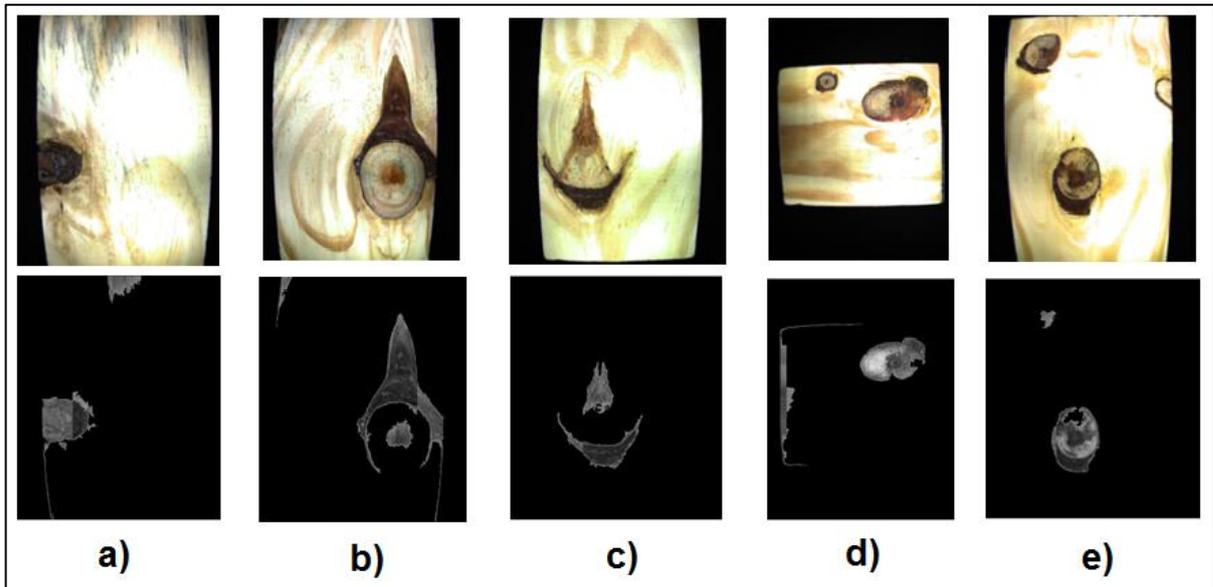
O método apresenta melhores resultados na presença de um único nó na imagem. A Tabela 4 apresenta a matriz de confusão para o número de nós por imagem. Neste caso, foram consideradas as 851 imagens em que foi detectado ao menos um nó. Desta forma, verificou-se quais as imagens com apenas um nó em que foi detectado também apenas um, e assim por diante para as quantias de dois e três nós. É evidente que para as amostras com apenas um nó houve alguns falsos alarmes: em 30 imagens que continham apenas um nó, foram indicados 2 nós e em 3, detectou-se incorretamente 3 nós. Para estas imagens, os erros da detecção se deram por variações significativas na tonalidade da madeira, mesmo que em regiões sem nós (Figura 17a), além de presença de outros defeitos não identificados (Figura 17b). Além disso, a má formação de nós também foi prejudicial para a localização de nós. A Figura 17c mostra um caso onde um nó foi segmentado incorretamente e o sistema considera a existência de dois nós. Para as imagens que possuíam 2 nós, houve um erro relacionado com o tamanho consideravelmente reduzido do defeito em questão e outro relacionado com a iluminação não homogênea que acabou gerando pontos mais escuros, acarretando em falso alarme (Figura 17d). Por fim, não foi identificado um nó de uma imagem que possuía 3 nós porque a região interna do mesmo era clara e estava situada sobre a borda da madeira (Figura 17e).

Tabela 4 – Matriz de confusão da detecção de nós por quantidade.

		Nós presentes		
		1	2	3
Nós detectados	1	772	1	0
	2	30	42	1
	3	3	0	2

Fonte: O autor (2018).

Figura 17 – Erros de segmentação. a) Variações de tonalidade da madeira limpa. b) Defeitos não identificados. c) Má formação de nós. d) Tamanho reduzido de nós e iluminação não homogênea. e) Nó com região central clara localizado sobre a borda da madeira.



Fonte: o autor (2018).

Visando a determinação do desempenho para cada grupo de imagens de 1, 2 ou 3 nós na detecção, foram calculados os valores de FNR, Precisão e *Recall*. A Tabela 5 apresenta os dados por número de nós presentes nas amostras. É possível verificar que a detecção para imagens que continham 2 ou 3 nós foi prejudicada pela baixa quantidade de amostras, onde um erro teve maior relevância do que se comparado com os agrupamentos maiores.

Tabela 5 – Desempenho na detecção por quantidade de nós

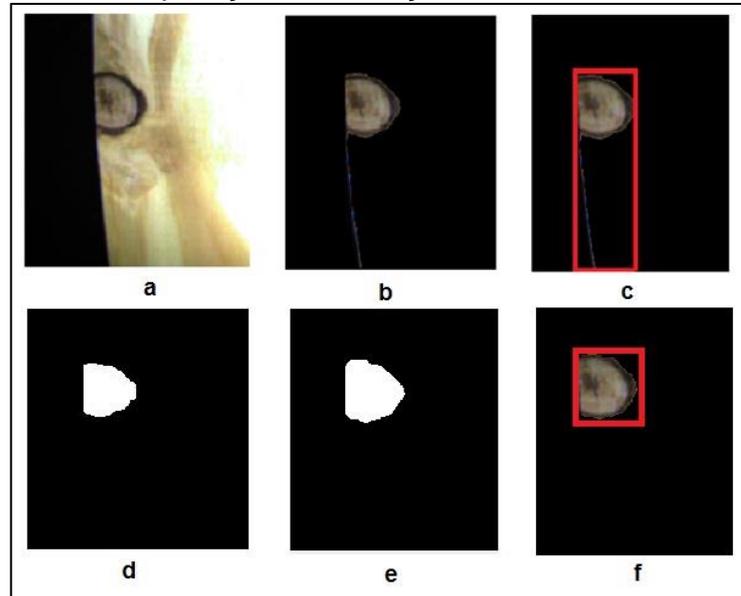
	1 nó	2 nós	3 nós
FNR	4,10%	2,32%	33,30%
Precisão	99,87%	56,70%	40,00%
Recall	95,89%	97,67%	66,66%

Fonte: O autor (2018).

3.7.2 Resultados na localização do nó

Com os nós detectados e enquadrados, com a sua área retangular e centroide definidos, calcula-se o valor do erro na localização de cada nó em relação ao seu centro. O RMSE médio calculado para a localização do centroide de cada nó, das 897 amostras corretamente segmentadas de 8,8 pixels, o que equivale a aproximadamente 1,7 mm e desvio padrão de 14,8 pixels (2,9 mm). O *boxplot* obtido a partir dos RMSE de cada imagem pode ser visto na Figura 19a. Observa-se a existência de diversos *outliers*, um até mesmo beirando os 90 pixels. Como pretende-se implementar um sistema que localize nós em qualquer região da imagem mesmo que próximo às bordas da madeira, diferentemente da bibliografia pesquisada, inicialmente a localização foi prejudicada, conforme pode ser visto na Figura 18c. Isso porque a tonalidade da linha da borda da madeira é semelhante ao limiar definido para a binarização da imagem inicialmente. Para amenizar os efeitos das bordas da madeira na localização, implementou-se uma etapa de erosão matemática com elemento estruturante em forma de disco, com raio 2 px e mais quatro etapas também de erosão com um raio menor, de 1 px. Em seguida, faz-se a dilatação, no mesmo número de etapas e raios dos elementos estruturantes que as erosões. Alcançou-se desta forma, um RMSE médio de 4,7 pixels, o que equivale a aproximadamente 0,9 mm e desvio padrão 7,9 pixels (1,5 mm). O resultado pode ser observado na Figura 18f e o *boxplot*, na Figura 19b. Assim, conclui-se que houve redução da magnitude da média e valor máximo do RMSE, *outliers* e a magnitude máxima dos mesmos.

Figura 18 – Segmentação de nó próximo à borda da madeira. a) nó localizado sobre a borda da madeira. b) Resultado da segmentação sem operação de remoção de bordas. c) Detecção da área do nó prejudicada. d) Máscara da imagem após erosões. e) Máscara da imagem após dilatações. f) Resultado da segmentação com operação de remoção de bordas.



Fonte: o autor (2018).

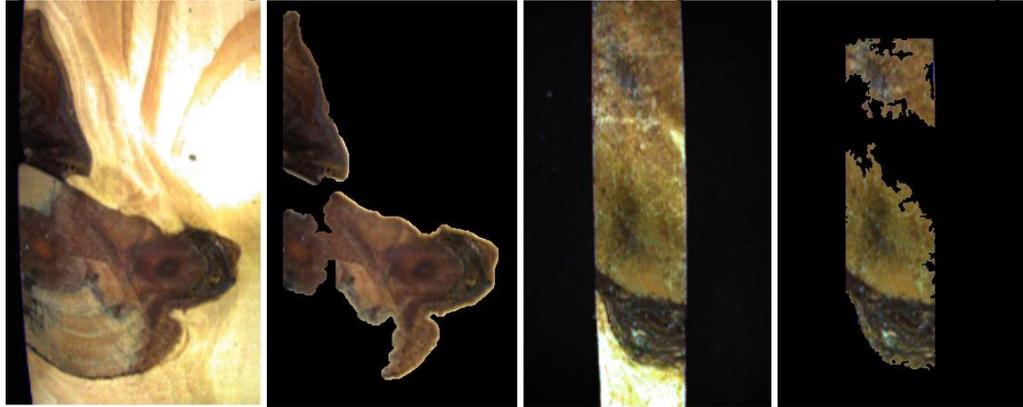
Figura 19 – *Boxplot* do RMSE calculado por imagem. a) Sem operação de remoção de bordas. b) Com operação de remoção de bordas.



Fonte: o autor (2018).

O principal motivo para os dois maiores *outliers* se deu por conta da incorreta segmentação de nós grandes, de tamanhos incomuns, conforme Figura 20. Em ambos, nota-se que existem regiões claras no interior desses defeitos, fazendo com que o mesmo nó seja repartido na segmentação e interpretado como dois nós.

Figura 20 – Erros geradores dos *outliers* mais significativos na localização.



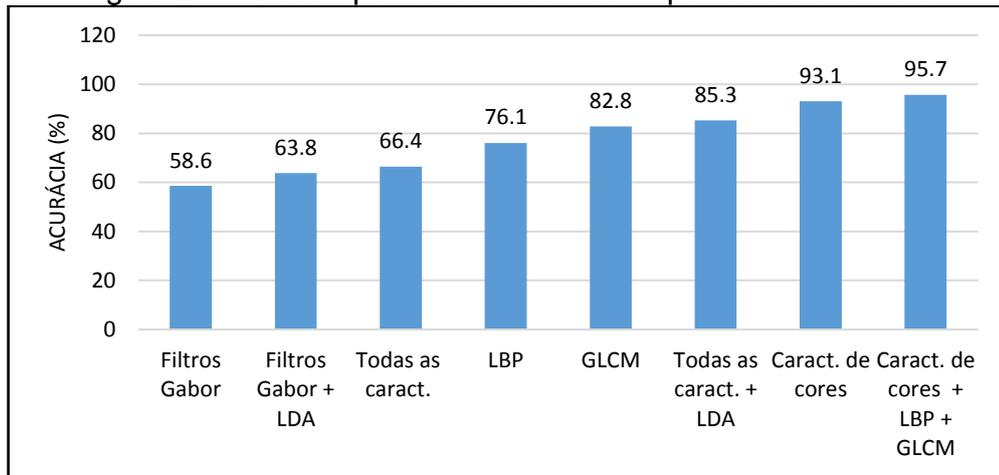
Fonte: o autor (2018).

3.7.3 Resultados obtidos na classificação

Como alguns nós da base de dados foram considerados como não identificados, conforme abordado na Seção 3.2, a classificação foi feita a partir de um total de 707 imagens de nós, sendo 301 pertencentes à classe *sound*, 201 à classe *dead* e 184 à classe *rotten*. 456 foram utilizados para treinamento, 114 para validação e 116 para teste, distribuídos aleatoriamente. Para tanto, são comparados os resultados utilizando-se as características oriundas da aplicação de filtros Gabor, LBP, GLCM e obtidas a partir de cores, conforme visto na Seção 3.4, além de diferentes combinações entre si. Sendo as amostras consideradas como corretamente segmentadas, sem a influência de erros na segmentação.

Utilizando a rede neural MLP, o melhor desempenho foi obtido para a combinação das características de cores, juntamente com LBP e GLCM. A Figura 21 mostra os resultados para a rede neural MLP com as características individuais e combinações delas. Mesmo não tendo os melhores desempenhos, os vetores com as maiores dimensionalidades, apresentaram uma melhora em sua acurácia, após a transformação e redução do espaço de características por LDA.

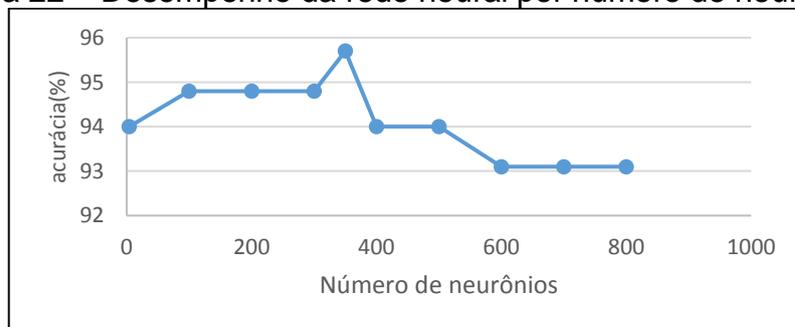
Figura 21 – Desempenho da rede neural por características.



Fonte: o autor (2018).

Para estimar o número de neurônios da rede, foram feitos alguns testes com a rede neural descrita, utilizando as características de cores, LBP e GLCM. Nesta configuração, a rede foi treinada até que se encontrasse a máxima acurácia possível com alguns números de neurônios pré-definidos. Desta forma, a maior acurácia encontrada foi de 95,7% utilizando 350 neurônios, para a rede MLP. O gráfico do desempenho pelo número de neurônios pode ser visualizado na Figura 22.

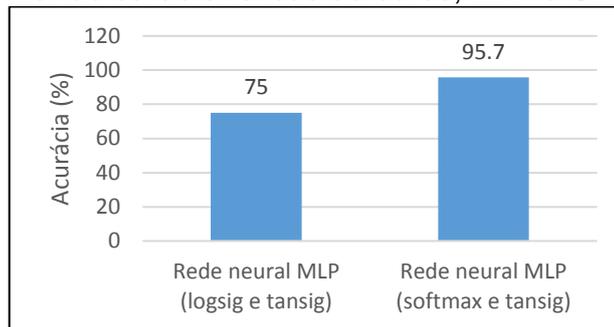
Figura 22 – Desempenho da rede neural por número de neurônios.



Fonte: o autor (2018).

YongHua, et al (2015), Xiang, et al (2016) e Marcano-Cedeño, et al(2009) implementam redes neurais MLP com tangente hiperbólica (Tanh) como função de transferência da entrada para a camada oculta, enquanto que da camada oculta para a saída, é utilizada a função *Logsig*, *S-logarithmic*. Foi então executada a classificação utilizando estas funções, atingindo uma acurácia de 75%, enquanto que a implementação da rede utilizando as funções *Softmax* e *Tanh* em conjunto produziu um desempenho superior, com 95,7%, conforme mostrado na Figura 23.

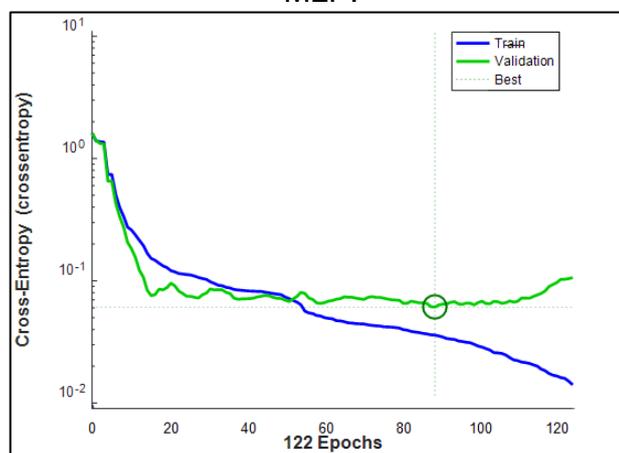
Figura 23 – Desempenho da rede neural com diferentes funções de ativação utilizando características de cores, LBP e GLCM.



Fonte: o autor (2018).

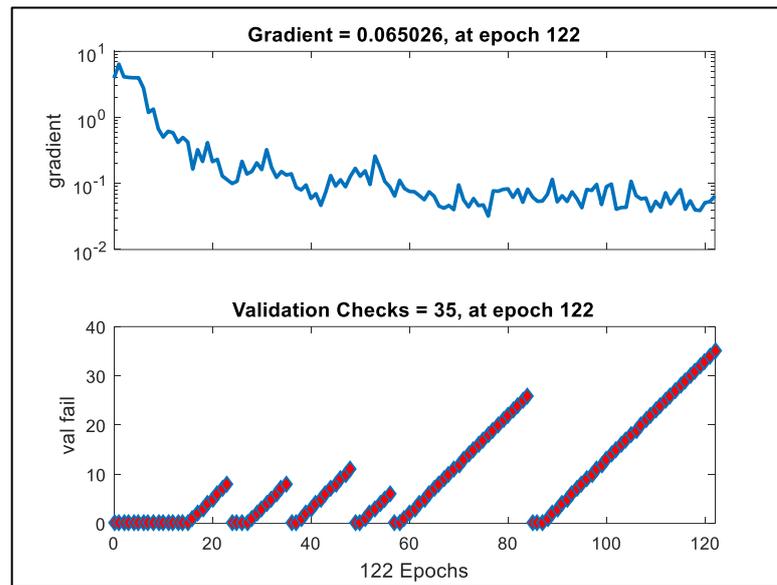
A Figura 24 mostra as curvas de desempenho das redes para os dados de validação conforme as épocas de treinamento. O melhor desempenho é dado pelo menor valor de entropia cruzada para os dados de validação na 87ª época de treinamento. A partir deste ponto, são executadas 35 checagens de validação, resultando em 122 interações para o treinamento da rede, conforme pode ser observado na Figura 25. Também é exibido o gráfico do gradiente no decorrer do treinamento.

Figura 24 – Ponto de melhor desempenho para os dados de validação – primeira MLP.



Fonte: o autor (2018).

Figura 25 – Gráfico do gradiente e checagens de validação durante o treinamento da rede.



Fonte: o autor (2018).

O resultado final da classificação, utilizando a rede MLP, com 350 neurônios, funções de transferência *Softmax* e *Tanh*, com características de cores, LBP e GLCM é exibido pela matriz de confusão da Tabela 6 e também pelos dados de desempenho dados pela Tabela 7. É evidente que a classificação das classes *dead* e *rotten* foram as que apresentaram os maiores erros. A Figura 26 mostra alguns nós da classe *rotten* que foram classificados incorretamente. Isso se deve às regiões mais claras no interior destes defeitos, bem como a diferença visível entre a borda e a região interna a textura homogênea presente também na região do centro.

Tabela 6 – Matriz de confusão da classificação.

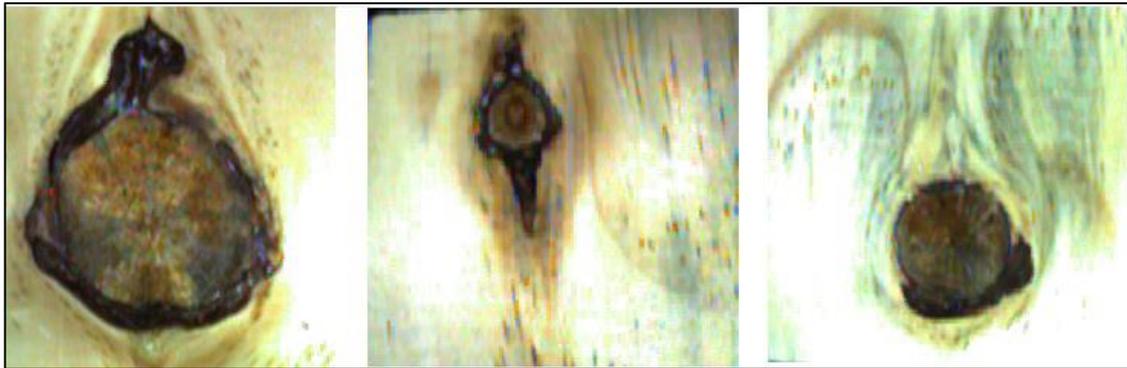
		<i>sound</i>	<i>dead</i>	<i>Rotten</i>
Tipo de nó detectado	<i>sound</i>	51	0	1
	<i>dead</i>	0	33	3
	<i>rotten</i>	0	1	27

Fonte: O autor (2018).

Tabela 7 – Desempenho na classificação por tipo de nó

	<i>sound</i>	<i>Dead</i>	<i>Rotten</i>
FNR	0%	2,9%	12,9%
Precisão	98,1%	91,7%	96,4%
Recall	100%	97,1%	87,1%

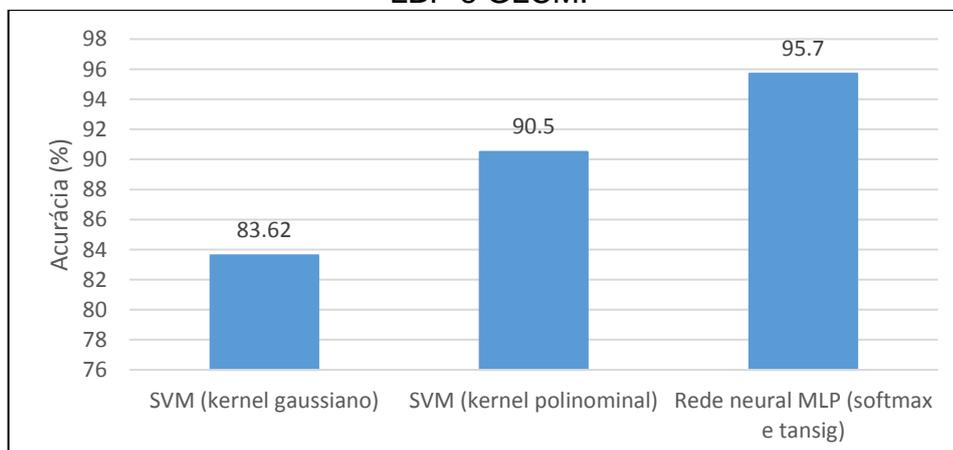
Fonte: O autor (2018).

Figura 26 – Nós da classe *rotten* classificados incorretamente.

Fonte: O autor (2018).

Estas características, juntamente com a configuração da rede neural foram então escolhidas para compor o classificador proposto. Contudo, como tentativa de melhorar a acurácia na classificação, foi implementado um método alternativo utilizando-se dois SVMs, com as características de cores e LBP e GLCM. A arquitetura proposta com SVM consiste em um reconhecimento hierárquico de padrões, conforme definido na Seção 3.5. Foram utilizados *kernels* gaussiano e polinomial como forma de comparação. A Figura 27 apresenta um comparativo de seus desempenhos em relação à rede neural MLP implementada anteriormente.

Figura 27 – Desempenho dos classificadores utilizando características de cores, LBP e GLCM.



Fonte: o autor (2018).

4 CONCLUSÕES

A detecção e classificação de nós de madeira estão diretamente ligadas ao controle de qualidade na produção de móveis, esquadrias, cepas de escovas e outros. Uma vez que estes defeitos possam significar características visuais e estruturais indesejadas, seu descarte faz-se necessário. No entanto, há aplicações onde determinados tipos de defeitos não são prejudiciais e, portanto, a rejeição da matéria-prima que os contém pode significar desperdício. Desta forma, a classificação também constitui um papel de melhorar o aproveitamento da matéria-prima, destinando um material não homogêneo para uma aplicação apropriada, ao invés de simplesmente descartá-lo, por exemplo, como é feito em alguns países da Europa. Estes países possuem regras próprias de categorização da madeira conforme os tipos de defeitos presentes e também suas quantidades por área.

Diversas tecnologias já foram utilizadas para a detecção e classificação de defeitos em madeira, como forma de substituir o trabalho do ser humano para tal função. Isso porque o desempenho do mesmo é limitado devido à fadiga ocular e julgamento subjetivo. No entanto, os melhores resultados para reconhecimento de nós em placas de madeira serrada são obtidos a partir de sistemas de visão. Além disso, sistemas ópticos possuem custos relativamente mais baixos do que outras tecnologias, o que viabiliza sua aplicação em linhas de produção de empresas madeireiras de pequeno e médio porte. Desta forma, optou-se por uma câmera CCD como sensor para o sistema proposto.

O objetivo deste trabalho foi desenvolver um sistema completo para a localização e classificação de nós em madeira composto por sistema óptico para aquisição de imagens, base de dados, bloco de segmentação, bloco de extração de características e classificador. Através do sistema para aquisição de imagens, coletou-se uma base de dados de 1000 imagens, das quais 900 continham nós. Todas elas foram manualmente rotuladas quanto à sua localização e 707 rotuladas quanto ao seu tipo. Com isso, fez-se um comparativo entre dois métodos distintos de segmentação de nós: por filtros Gabor e por reconstrução morfológica. Os testes preliminares apontaram que apenas o segundo produziu uma segmentação adequada para a localização e classificação. Após a segmentação então, fez-se o enquadramento dos nós para que a localização de seu centroide fosse estimado e se pudesse calcular o erro em relação aos dados oriundos da rotulação manual. A extração de

características contou com 9 características geradas a partir de cores das camadas do RGB, 10 de texturas do LBP, 14 da GLCM e 2304 extraídas utilizando um banco de filtros Gabor de 36 filtros. Devido à sua alta dimensionalidade, buscou-se a redução do espaço de características Gabor pela implementação da análise de discriminante linear. Por fim, foram implementados dois classificadores utilizando diferentes arranjos de características e parâmetros: uma rede neural *Multilayer Perceptron* e um SVM.

Visando à determinação da eficiência do algoritmo como um todo, foram tomadas medidas de desempenho para a detecção binária de presença de nós por imagem, quantidade de nós detectados por imagem, localização do centroide do nó e classificação. Para a detecção por imagem, foi obtida uma acurácia de 94,4%, precisão de 99,2% e recall de 94,6%. Além disso, as medidas de desempenho da detecção por quantidade de nós foram divididas em três grupos: as imagens que continham um nó foram detectadas com 99,9% e 95,9% de precisão e *recall*, respectivamente. As imagens que continham dois nós foram detectadas com 56,7% e 97,7% para as mesmas medidas. As amostras com 3 nós apresentaram os piores resultados, com 40% e 66,7% de precisão e recall respectivamente. Na localização, o RMSE médio foi de 4,7 pixels que representa aproximadamente 0,9 mm e desvio padrão de 7,9 pixels (1,5 mm). Por fim, o melhor resultado obtido na classificação foi de 95,7% de acurácia, com a utilização de redes neurais MLP, características de cores, LBP e GLCM, Softmax e Tanh como funções de ativação e 350 neurônios.

A detecção apresentou problemas devido à tonalidade clara de alguns nós do tipo *dead*. A localização foi prejudicada pela existência de áreas esbranquiçadas próximo ao centro dos nós que acabaram gerando fragmentação de sua área e, conseqüentemente, a existência de mais de um centroide para o mesmo nó. A classificação, por sua vez, teve problemas devido à variabilidade de cores e texturas para o mesmo tipo de nó, bem como semelhança de algumas características para classes diferentes.

Propõe-se para trabalhos futuros, a implementação de um programa capaz de detectar áreas circulares para melhorar o desempenho da detecção. Isto porque os nós não detectados possuem dimensões reduzidas, com formas que tendem a ser circulares. Desta forma, como há independência da tonalidade das cores na detecção, é provável que os resultados sejam melhores em relação aos encontrados neste trabalho.

REFERÊNCIAS

- ABNT. **Madeira serrada de coníferas e de folhosas**. Disponível em: <
<http://www.abnt.org.br/noticias/3797-madeira-serrada-de-coniferas-e-de-folhosas>>.
 Acesso em: 04 out. 2017.
- AIYMATTARNEH, Hashem M. A., Ghodgaonkar, Deepak K. e Majid, Wan Mahmood b. W. A. 2001. Microwave nondestructive testing for classification of malaysian timber using free-space techniques. **International Symposium on Signal Processing and its Applications (ISSPA)**. pp. 450 - 453. 2001,
- ALLIED VISION TECHNOLOGIES GMBH. 2015. **Guppy - Technical Manual**. V7.4.1. Stadtroda/Germany, 2015.
- BACHA, Carlos José Caetano. **Os mercados de produtos florestais no Brasil**. Centro de Estudos Avançados em Economia Aplicada. Disponível em: <
<http://www.cepea.esalq.usp.br/br/opiniao-cepea/os-mercados-de-produtos-florestais-no-brasil.aspx>>. Acesso em: 27 mar. 2017.
- BARADIT, E., Aedo, R. e Correa, J. Knots detection in wood using microwaves. **Wood Sci Technol**. Vol. 40, pp. 118–123. 2006.
- BELLMAN, R. **Adaptive Control Processes**. Princeton : Princeton University Press, 1961.
- BHANDARKAR, Suchendra M. e Tang, Timothy D. Faust and Mengjin. A Computer Vision System for Lumber Production Planning. **Applications of Computer Vision**. pp. 134 - 139. 1998.
- CHAI, T. e Draxler, R. R. 2014. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. **Geosci. Model Dev**, Vol. 7, pp. 1247–1250. 2014.
- CONNERS, Richard W., et al..A machine vision system for automatically grading hardwood lumber. **Elsevier Industrial Metrology**. Vol. 2, pp. 317-342. 1992.
- CONNERS, Richard W., et al.. Identifying and Locating Surface Defects in Wood: Part of an Automated Lumber Processing System. **IEEE transactions on pattern analysis and machine intelligence**. Vol. 5, No. 6, pp. 573-583.1983.
- DAWEI Qi, Li Li. 2007. Nondestructive Testing Wood Internal Defects by Fractional Brownian Motion Processor. **International Conference on Mechatronics and Automation**. pp. 1234 - 1239. Agosto de 2007.
- DEVARU, Dayakar, et al.. Algorithm for Detecting Defects in Wooden Logs Using Ground Penetrating Radar. **Intelligent Systems in Design and Manufacturing**. IV, Vol. 5999, pp. 59990B-1 - 59990B-12. 2005.

DUDA, Richard O., Hart, Peter E. e Stork, David G. **Pattern Classification**. 2001.

FORDAQ S.A. Wood quality norms. **The Timber Network**. Disponível em: <http://www.fordaq.com/html/quality_mainmenu_En.htm>. Acesso em: 27 Set. de 2017.

FUNCK, J. W., et al. Image segmentation algorithms applied to wood defect detection. **Elsevier Computers and Electronics in Agriculture**. Vol. 41, pp. 157-179. 2003.

GEOMATICS, PCI. **Geometric features**. Disponível em: <http://www.pcigeomatics.com/geomatica-help/concepts/focus_c/oa_featExtract_intro_geoFeat.html>. Acesso em: 7 Nov. 2017.

GRÖNLUND, Cilla. **Quality improvements in forest products industry**. Tese de doutorado. Suécia : Lulea University of Technology, 1995.

GU, Irene Yu-Hua, Andersson, Henrik e Vicen, Raul. Wood defect classification based on image analysis and support vector machines. **Wood Sci Technol**. Vol. 44, pp. 693–704. 2010.

HAGHIGHAT, M., Zonouz, S. e Abdel-Mottaleb, M. CloudID: Trustworthy cloud-based and cross-enterprise biometric identification. **Expert Systems with Applications**. Vol. 42, Issue 21, pp. 7905-7916. 2015.

HALABE, Udaya B., Agrawala, Sachin e Gopalakrishnan, Bhaskaran. Nondestructive evaluation of wooden logs using ground penetrating radar. **Nondestructive Testing and Evaluation**. 4, Vol. 24, pp. 329–346. 2009.

HANSSON, Mattias, Enescu, Alexandru e Brandt, Sami S. 2015. Knot Detection in X-ray Images of Wood Planks using Dictionary Learning. **IAPR International Conference on Machine Vision Applications (MVA)**. 14, pp. 497 - 500. Maio de 2015.

HARALICK, R. M., Shanmugam, K. e Dinstein, I. 1973. Textural Features of Image Classification. **IEEE Transactions on Systems, Man and Cybernetics**. Vols. SMC-3, no. 6. 1973.

HAYKIN, Simon. **Neural Networks - A Comprehensive Foundation**. 2^a. New Jersey : Prentice Hall International, Inc., 1999.

HITTAWEA, Mohamad Mazen, et al.. Multiple features extraction for timber defects detection and classification using SVM. **ICIP 2015 IEEE**. 2015.

HU, Chuanshuang, et al.. Automatic detection of sound knots and loose knots on sugi using gray level co-occurrence matrix parameters. **Annals of Forest Science**. Vol. 68, pp. 1077–1083. 2011.

HU, Chuanshuang, Tanaka, Chiaki e Ohtani, Tadashi. Locating and identifying sound knots and dead knots on sugi by the rulebased color vision system. **The Japan Wood Research Society**. pp. 427-431. 2004.

HUBER, Henry A., McMillin, Charles W. e McKinney, John P.. Lumber defect detection abilities of furniture rough mill employees. **Forest products jornal**. Vol. 35, No. 11/12, pp. 79-82. 1985.

JAIN, Anil K. e Farrokhnia, Farshid. Unsupervised Texture Segmentation Using Gabor Filters. **International Conference on Systems, Man, and Cybernetics Conference Proceedings**. 1990.

LI, Chao, et al. Soft measurement of wood defects based on LDA feature fusion and compressed sensor images. **Northeast Forestry University and Springer-Verlag Berlin Heidelberg**. 2017.

LI-HAI, Wang, et al. 2007. Effect of sensor quantity on measurement accuracy of log inner defects by using stress wave. **Journal of Forestry Research**. Vol. 18, pp. 221 - 225 . 2007.

LONGUETAUD, F., et al. 2012. Automatic knot detection and measurements from X-ray CT images of wood: A review and validation of an improved algorithm on softwood samples. **Computers and Electronics in Agriculture**. Vol. 85, pp. 77 - 89. 2012.

LUGADE, Vipul, et al. 2014. An Artificial Neural Network Estimation of Gait Balance Control in the Elderly Using Clinical Evaluations. **PloS one**. e97595., Vol. 9. 2014.

MARCANO-CEDEÑO, Alexis, Quintanilla-Domínguez, J. e Andina, D. Wood Defects Classification Using Artificial Metaplasticity Neural Network. Industrial Electronics, 2009. IECON '09. **35th Annual Conference of IEEE**, pp. 3422 - 3427. 2009.

MATHWORKS. **Morphological operations on binary images**. Documentation. Disponível em: < <https://www.mathworks.com/help/images/ref/bwmorph.html>>. Acesso em: 12 jul. 2018.

MU, Hongbo e Qi, Dawei. Recognition of Wood Defects Based on Artificial Neural Network. **International Conference on Advanced Intelligent Mechatronics**, pp. 1232 - 1237. Julho de 2008.

NAGAI, Hiroaki, Murata, Koji e Nakano, Takato. Defect detection in lumber including knots using bending deflection curve: comparison between experimental analysis and finite element modeling. **The Japan Wood Research Society**. Vol. 55, pp. 169–174. 2009.

OH, Jung-Kwon, et al. 2009. Quantification of knots in dimension lumber using a single-pass X-ray radiation. **The Japan Wood Research Society**. Vol. 55, pp. 264-272. 2009.

OJALA, Timo, Pietikäinen, Matti e Mäenpää, Topi. Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns. **IEEE Transactions on pattern analysis and machine intelligence**. Vol. 24, NO. 7, pp. 971-987, 2002.

PÖLZLEITNER, W. e Schwingshagl, G. **Real-time surface grading of profiled wooden boards. Industrial Metrology**. Vol. 2, pp. 283-298, 1992.

REVERDY, Paul e Leonard, Naomi Ehrich. Parameter Estimation in Softmax Decision-Making Models With Linear Objective Functions. **IEEE Transactions on automation science and engineering**,.Vol. 13, NO. 1, pp. 54-67, 2016.

RICE, R. W. e Kumar, P. H. Steele and Lalit. Detecting knots and voids in lumber with dielectric sensors. **Industrial Metrology**. Vol. 2, pp. 309-315. Elsevier, 1992.

SARIGUL, Erol, Abbott, A. Lynn e Schmoltdt, Daniel L. Rule-driven defect detection in CT images of hardwood logs. **Computers and Electronics in Agriculture**. Vol. 41, pp. 101 - 119, 2003.

SCHAFER, Mark E. Ultrasound for defect detection and grading in wood and lumber. **IEEE Ultrasonics Symposium**. pp. 771 - 778, 2000.

SOH, Leen-Kiat e Tsatsoulis, Costas. Texture Analysis of SAR Sea Ice Imagery Using Gray Level Co-Occurrence Matrices. **IEEE transactions on geoscience and remote sensing**. Vol. 37, NO. 2, pp. 780-795, 1999.

SUN, Tianyong, Luo, Jing e Wang, Lihai. Research on Detecting Defects of Square-edged Timber of Fir and Ribbed Birch by Infrared Thermal Imager. **International Conference on Biobase Material Science and Engineering (BMSE)**. pp. 258-261, 2012.

THARWAT, Alaa, et al. Linear discriminant analysis: A detailed tutorial. **AI Communications**. Vol. 30, pp. 169-190, 2017.

THOMAS, Ed, et al. Primary Detection of Hardwood Log Defects Using Laser Surface Scanning. **Proceedings of SPIE-IS&T Electronic Imaging, SPIE**. Vol. 5011, pp. 39 - 49, 2003.

TODOROKI, C.L., Lowell, E.C. e Dykstra, D. 2010. Automated knot detection with visual post-processing of Douglas-fir veneer images. **Computers and Electronics in Agriculture**. Vol. 70, pp. 163–171, 2010.

TÖRMÄNEN, Veli-Matti O. e Mäkynen, Anssi J. Detection of knots in veneer surface by using laser scattering based on the tracheid effect. **International Instrumentation and Measurement**. Maio de 2009.

ÜNSALAN, Cem e Erçil, Aytül. **Defect inspection of wood surfaces**. Istanbul : Bogaziçi University, 1998.

VAPNIK, V. N. **The nature of statistical learning theory**. 1995.

VAPNIK, V.N. e Chervonenkis, A. Y. 1971. On the uniform convergence of relative frequencies of events to their probabilities. **Theory of Probability and Its Applications**. Vol. 16, pp. 264-280, 1971.

VETTERLING, William T., et al. **Numerical recipes in c: The art of scientific computing**. 2ª Edição. Cambridge : Cambridge University Presse, pp. 610-615, 2002.

WENSHU, Lin, Lijun, Shao e Jinzhuo, Wu. Study on Wood Board Defect Detection Based on Artificial Neural Network. **The Open Automation and Control Systems Journal**. 2015, Vol. 7, pp. 290-295, 2015.

XIANG, Zhang Yi, et al. Identification of Wood Defects Based on LBP Features. Proceedings of the 35th **Chinese Control Conference**. pp. 4202 - 4205, 2016.

YONGHUA, Xie e Jin-Cong, Wang. Study on the identification of the wood surface defects based on texture features. **Optik**. Vol. 126, pp. 2231–2235, 2015.

ZHANG, Yizhuo, et al. A rapid, automated flaw segmentation method using morphological reconstruction to grade wood flooring. **Journal of Forestry Research**. Vol. 25, 4, p. 959–964, 2014.

ZHANG, Yizhuo, et al. Wood defect detection method with PCA feature fusion and compressed sensing. **Northeast Forestry University and Springer-Verlag Berlin Heidelberg**. Vol. 26, 3, pp. 745–751, 2015.

ZHAO, Zhiling, Fan, Shangchun e Zheng, Dezhi. Non-destructive Testing of Solid Wood Plate using Variable Permittivity Plate Capacitor. **IEEE International Symposium on Instrumentation and Control Technology (ISICT) Proceedings**. 8th, 2012.

ZUNINO, Rodolfo e Gastaldo, Paolo. Analog implementation of the soft-max function. **IEEE International Symposium**. 2002.

APÊNDICE A – CÓDIGO-FONTE DA ETAPA DE PRÉ-PROCESSAMENTO

```

% segmentação de nós:

% O seguinte programa abre as imagens contidas na base de dados e rotuladas
% pelo arquivo "alvo1020", o qual contém as coordenadas dos nós,
estabelecidas
% manualmente.

% Após o arquivo de imagem especificado por "alvo1020", são definidos os
% limites da madeira, excluindo da etapa de segmentação todas as linhas
% e colunas que contenham sua média igual ou próximo a zero.

% Com isso, faz-se:
% Correção da luminosidade;
% Binzarização da imagem;
% Segmentação proposta por Zhang, et al (2014);
% Erosão e dilatação matemática para exclusão das bordas da madeira;
% Reenquadramento dos nós em regiões retangulares
% Preenchimento de matriz denominada "resultado_seg" com a coordenadas
encontradas

% Antes de iniciar a segmentação, importar o arquivo alvo como matriz
% numérica e a coluna 4 como vetor. Nomear o mesmo como 'R'.
% O arquivo "alvo1020" contém os rótulos das 1000 imagens coletadas.

% Nome: Alexander Augusto Dellabetha
% Universidade de Caxias do Sul
% Curso de Engenharia Eletrônica
% Data: 14/06/2018

%


---


%Variáveis para determinação das áreas do nó

atualiza_linhas = 0;
nros = 0;
resultado_seg = zeros();
resultado_det = zeros();
alvoanterior = 0;
k=12;

%ETAPA PARA ENCONTRAR OS LIMITES DA MADEIRA

while(k < 722)

    %Abre imagens da madeira

    if(alvoanterior ~= alvo1020(k,1))

        A = imread('17.bmp');

        Agray = rgb2gray(A);
        toc
        %variaveis para determinar limites da madeira
        y_iniciomadeira=1;

```

```

y_finalmadeira=768;
x_iniciomadeira=1;
x_finalmadeira=492;

%constantes para varredura para encontrar limites da madeira
xi=1;
xm1 = 180;
xm2 = 350;
xf=492;
yi=1;
ym1=300;
ym2=400;
ym3=450;
yf=768;

%nível de cinza que representa a presença de madeira
fc = 110;

%varredura para encontrar início e fim da área que contém madeira
while ((Agray(xi,y_iniciomadeira)<fc &&
        Agray(xm1,y_iniciomadeira)<fc && Agray(xm2,y_iniciomadeira)<fc
        && Agray(xf,y_iniciomadeira)<fc) && y_iniciomadeira <494)
    y_iniciomadeira =y_iniciomadeira +1;
end;

while((Agray(xi,y_finalmadeira)<fc && Agray(xm1,y_finalmadeira)<fc
        && Agray(xm2,y_finalmadeira)<fc &&
        Agray(xf,y_finalmadeira)<fc)&& y_finalmadeira >1)
    y_finalmadeira = y_finalmadeira - 1;
end;

while ((Agray(x_iniciomadeira,yi)<fc &&
        Agray(x_iniciomadeira,ym1)<fc && Agray(x_iniciomadeira,ym2)<fc
        && Agray(x_iniciomadeira,yf)<fc) && x_iniciomadeira <476)
    x_iniciomadeira =x_iniciomadeira +1;
end;

while((Agray(x_finalmadeira,yi)<fc && Agray(x_finalmadeira,ym1)<fc
        && Agray(x_finalmadeira,ym2)<fc &&
        Agray(x_finalmadeira,yf)<fc)&& x_finalmadeira >1)
    x_finalmadeira = x_finalmadeira - 1;
end;

%define área correspondente à madeira
A_result = Agray(x_iniciomadeira:x_finalmadeira
                ,y_iniciomadeira:y_finalmadeira);

% Etapa de correção de luminonisidade
% Esta etapa "clareia" as laterais da imagem, devido à luminosidade
% insuficiente provida pela iluminação auxiliar

x = 1;
y = 1;
seg1 = zeros (492, 768);
Acopia = rgb2gray(A);
A = Acopia;
%constantes que determinam quais áreas da imagem serão clareadas
yclear1=170;
yclear2=280;

```

```

while(yclear1<yclear2)
    xclear = 1;
    while(xclear<493)
        if(A(xclear,yclear1)<230 && A(xclear,yclear1)>15 )
            if( 492 - 130 < xclear && xclear < 130)
                A(xclear,yclear1) = A(xclear,yclear1) + 83;
            else
                A(xclear,yclear1) = A(xclear,yclear1) + 50;
            end
        end
        xclear = xclear + 1;
    end
    yclear1 = yclear1 + 1;
end

%constantes que determinam áreas a serem clareadas
yclear3=500;
yclear4=570;

while(yclear3<yclear4)
    xclear = 1;
    while(xclear<493)
        if(A(xclear,yclear3)<230 && A(xclear,yclear3)>15 )
            if( 492 - 130 < xclear && xclear < 130)
                A(xclear,yclear3) = A(xclear,yclear3) + 83;
            else
                A(xclear,yclear3) = A(xclear,yclear3) + 50;
            end
        end
        xclear = xclear + 1;
    end
    yclear3 = yclear3 + 1;
end

%determina limiar binarização
limiar_grscl = 0.4*mode(mode(Agray(x_iniciomadeira:x_finalmadeira
    ,y_iniciomadeira:y_finalmadeira)))+0.12*median(median(Agr
    ay(x_iniciomadeira:x_finalmadeira
    ,y_iniciomadeira:y_finalmadeira)));

%binarização da imagem
while (x < 493)
    while (y < 769)
        if (A(x,y) < limiar_grscl && A(x,y) > 3 )
            Acopia(x,y) = 255;
        else
            seg1(x,y) = 0;
            Acopia(x,y) = 0;
        end
        y = y + 1;
    end
    y = 1;
    x = x + 1 ;
end

%encontra o esqueleto do nó (Zhang, 2014)
BW3 = bwmorph(logical(Acopia), 'skel', Inf);
BW3result = BW3;

```

```

%Operação de "poda" no esqueleto
x = 1;
while(x < 493)
    y = 1;
    while(y < 769)
        vizinhos_nnulos = 0;
        i = -1;
        while (i < 2)
            j = -1;
            while (j < 2)
                if(x+i>0 && y+j>0 && x+i<433 && y+j<299)
                    if(BW3((x+i), (y+j))~=0)
                        vizinhos_nnulos = vizinhos_nnulos + 1;
                    end
                    nhood((i+2), (j+2)) = BW3((x+i), (y+j));
                else
                    nhood((i+2), (j+2)) = 0;
                end
                j = j + 1;
            end
            i = i + 1;
        end
        y = y + 1;
        nborda_subida = 0;

        %lógica que calcula a quantidade de bordas de subida
        if(nhood(1,2)< nhood(1,3))
            nborda_subida = nborda_subida +1;
        end
        if(nhood(1,3)<nhood(2,3))
            nborda_subida = nborda_subida +1;
        end
        if(nhood(2,3)<nhood(3,3))
            nborda_subida = nborda_subida +1;
        end
        if(nhood(3,3)<nhood(3,2))
            nborda_subida = nborda_subida +1;
        end
        if(nhood(3,2)<nhood(3,1))
            nborda_subida = nborda_subida +1;
        end
        if(nhood(3,1)<nhood(2,1))
            nborda_subida = nborda_subida +1;
        end
        if(nhood(2,1)<nhood(1,1))
            nborda_subida = nborda_subida +1;
        end
        end

        %lógica que calcula a quantidade de bordas de descida
        nborda_descida = 0;

        if(nhood(1,2)> nhood(1,3))
            nborda_descida = nborda_descida +1;
        end
        if(nhood(1,3)> nhood(2,3))
            nborda_descida = nborda_descida +1;
        end
        if(nhood(2,3)>nhood(3,3))
            nborda_descida = nborda_descida +1;
        end
        end
    end
end

```

```

    if(nhood(3,3)>nhood(3,2))
        nborda_descida = nborda_descida +1;
    end
    if(nhood(3,2)>nhood(3,1))
        nborda_descida = nborda_descida +1;
    end
    if(nhood(3,1)>nhood(2,1))
        nborda_descida = nborda_descida +1;
    end
    if(nhood(2,1)>nhood(1,1))
        nborda_descida = nborda_descida +1;
    end

    %elimina pixel considerado como não pertencente ao
    %esqueleto principal, que satisfaz as condições descritas
    %por Zhang, et al (2014).

    if( (vizinhos_nulos<4) && nborda_subida==1 &&
        nborda_descida==1)
        BW3result(x,y) = 0;
    end

end
x = x + 1;
end

%preencher com '0' os pixels fora do requadramento da madeira
x = 1;
while(x < 493)
    y1=1;
    while(y1<(y_iniciomadeira + 1))
        BW3result(x,y1) = 0;
        Acopia(x, y1) = 0;
        y1 = y1+1;
    end

    y2=768;
    while(y2>(y_finalmadeira - 1))
        BW3result(x,y2) = 0;
        Acopia(x,y2) = 0;
        y2 = y2-1;
    end

    x = x + 1;
end

y = 1;
while(y < 769)
    x1=1;
    while(x1<(x_iniciomadeira + 1))
        BW3result(x1,y) = 0;
        Acopia(x1,y) = 0;
        x1 = x1+1;
    end

    x2=492;
    while(x2>(x_finalmadeira - 1))
        BW3result(x2,y) = 0;
        Acopia(x2,y) = 0;
        x2 = x2-1;
    end
end

```

```

        end
        y = y + 1;
    end

    %operação de reconstrução morfológica utilizando o esqueleto como
    %imagem semente
    marker = BW3result (1:492,1:768);
    im = imreconstruct(marker,logical(Acopia));

    %preenchimento morfológico dos "furos" da imagem
    I2 = imfill(im,'holes');

    %erosão matemática para eliminar segmentos indesejados
    erode_logic_result = I2;
    se = strel('rectangle',[10 20]);
    erodedBW = imerode(I2,se);
    BW1 = logical(erodedBW);
    BW1result = BW1;

    %Detecção por imagem: preenche matriz de resultados por imagem: se
    detectou nó,preenche
    %com 1, se não, 0
    if(mean(mean(BW1result))~=0)
        resultado_det(k,1) = alvo1020(k,1);
        resultado_det(k,2) = 1;
    else
        resultado_det(k,1) = alvo1020(k,1);
        resultado_det(k,2) = 0;
    end

    %extração do esqueleto da imagem já segmentada
    BW3 = bwmorph(BW1result,'skel',Inf);
    BW3result = BW3;

    %segunda etapa de reconstrução morfológica
    im = imreconstruct(BW3result,I2);

    %remove linhas das bordas
    se = strel('disk',2,8);
    erodedBW = imerode(im,se);
    BW1 = logical(erodedBW);
    BW1result = BW1;

    i = 1;
    while(i<4)
        se = strel('disk',1,8);
        erodedBW = imerode(BW1result ,se);
        BW1 = logical(erodedBW);
        BW1result = BW1;
        i=i+1;
    end

    %dilatação mofológica para repor pixels retirados pela erosão
    se = strel('disk',2,8);
    BW2 = imdilate(BW1result,se);
    BW1 = logical(BW2);
    BW1result = BW1;

    i=1;

```

```

while(i<4)
    se = strel('disk',1,8);
    BW2 = imdilate(BW1result,se);
    BW1 = logical(BW2);
    BW1result = BW1;
    i = i + 1;
end

im = BW1result;

%caso seja desejado, a imagem total segmentada em escala de cinza
%pode ser salva, bastando descomentar as linhas a baixo
%Asegm2=A.*uint8(im);
% imwrite(Asegm2,strcat(strcat('D',
    num2str(alvo1020(k,1))),'.bmp'));

%caso seja desejado, a imagem total segmentada colorida pode ser
%salva, bastando descomentar as linhas a baixo
%AC = imread(strcat(num2str(alvo1020(k,1)),'.bmp'));
%Asegm3(:, :, 1)=AC(:, :, 1).*uint8(im);
%Asegm3(:, :, 2)=AC(:, :, 2).*uint8(im);
%Asegm3(:, :, 3)=AC(:, :, 3).*uint8(im);
%imwrite(Asegm3,strcat(strcat('A',
    num2str(alvo1020(k,1))),'.bmp'));

%
%-----
%Denomina quantidade e áreas dos nós, além de preencher o
"resultado_seg"

%cria imagem a partir da imagem segmentada para sobrescrever áreas
%reenquadradas de nós
mnos = zeros(size(im));

%variáveis utilizadas para preenchimento do arquivo "resultado_seg"
contrl_tem_no = 0;
atualiza_linhas = atualiza_linhas + mnos;

x = 1;
mnos = 0;
while(x < 493)
    y = 1;
    controle_separa_nos = 0;

%encontra o primeiro ponto não nulo da imagem binária e adota as
%coordenadas (x,y) como o primeiro ponto do reenquadramento do nó
    while(y < 769)
        if(im(x,y,1) == 1 && mnos(x,y)==0)
            contrl_tem_no = 1;
            mnos = mnos + 1;
            limite1x = x;
            limite1y = y;
            limite2x = 0;
            limite2y = 0;
            y2 = y;
            x2 = x;

            %faz varredura para determinar o requadramento total
            %até que haja pixels não nulos
            while(y2 < 769 )

```

```

controle_ao_soma = 0;
if(mean(mean(im(limitex:492, y2))) == 0)
    controle_separa_nos = 1;
end

if(im(x2,y2,1)==1 )
    if(controle_separa_nos == 0)
        if(limite2y < y2 )
            limite2y = y2;
        end
    end
else
    if(x2<492 &&
        mean(im(x2+1,limitey:limite2y))~=0)
        x2 = x2+1;
        limite2x = x2;
        y2 = y;
        controle_ao_soma = 1;
    end
end
if(controle_ao_soma ==0 )
    y2 = y2 +1;
end
end

%laço para encontrar pontos do nó que ficaram para trás
em x
i = 1;
while(i<5)
    x3 = limitex;
    if isnan(mean(im(x3,limitey:limite2y)))
    else
        while(x3 > 1 &&
            mean(im(x3,limitey:limite2y))~=0))
            x3 = x3 - 1;
        end
        limitex = x3;
    end

    y3 = limitey;
    if isnan(mean(im(limitex:limite2x,y3)))
    else
        while(y3 > 1 &&
            mean(im(limitex:limite2x,y3))~=0))
            y3 = y3 - 1;
        end
        limitey = y3;
    end

    x3 = limite2x;
    if(x3 ==0)
        x3=1;
    end
    if isnan(mean(im(x3,limitey:limite2y)))
    else while(x3 < 493 &&
        mean(im(x3,limitey:limite2y))~=0))
            x3 = x3 + 1;
        end
        limite2x = x3;
    end
end

```

```

y3 = limite2y;
if(y3 == 0)
    y3 = 1;
end
if(limite2x > 492)
    limite2x = 492;
end
if isnan(mean(im(limite1x:limite2x,y3)))
else while(y3 < 769 &&
    mean(im(limite1x:limite2x,y3)~=0))
    y3 = y3 + 1;
end
limite2y = y3;
end

i=i+1;
end

%desenha área requadra dos nós
%se o tamanho do segmento tiver um tamanho mínimo para
%ser considerado um nó

areaencontrada = (limite2x - limite1x)*(limite2y -
    limitemy);
if(limite2x - limite1x > 3 && limite2y - limitemy > 3
    && areaencontrada>625)
    mnos(limite1x:limite2x,limitemy:limite2y)=1;
    mediax = floor((limite2x + limite1x)/2);
    mediay = floor((limite2y + limitemy)/2);

    %preenche matriz "resultado_seg" se o nó encontrado
    %não é o mesmo que anterior
    if(atualiza_linhas + nnos > 1)
        if(resultado_seg(atualiza_linhas - 1 + nnos,6)
            ~= limitemy && resultado_seg(atualiza_linhas -
            1 + nnos,7) ~= limite2y ||...

            resultado_seg(atualiza_linhas - 1 +
                nnos,4) ~= limite1x &&
            resultado_seg(atualiza_linhas - 1 + nnos,5) ~=
            limite2x ||...

            resultado_seg(atualiza_linhas - 1 + nnos,6) ~=
            limitemy && resultado_seg(atualiza_linhas - 1 +
            nnos,4) ~= limite1x || ...

            resultado_seg(atualiza_linhas - 1 + nnos,7) ~=
            limite2y && resultado_seg(atualiza_linhas - 1 +
            nnos,5) ~= limite2x ||...

            resultado_seg(atualiza_linhas - 1 + nnos,6) ~=
            limitemy && resultado_seg(atualiza_linhas -
            1 + nnos,5) ~= limite2x ||...
                resultado_seg(atualiza_linhas - 1 +
                nnos,4) ~= limite1x &&
            resultado_seg(atualiza_linhas - 1 + nnos,7) ~=
            limite2y)

```

```

        resultado_seg(atualiza_linhas + nnos,1) =
        alvo1020(k,1);

        resultado_seg(atualiza_linhas + nnos,2) =
        mediax;

        resultado_seg(atualiza_linhas + nnos,3) =
        mediay;

        resultado_seg(atualiza_linhas + nnos,4) =
        limite1x;

        resultado_seg(atualiza_linhas + nnos,5) =
        limite2x;

        resultado_seg(atualiza_linhas + nnos,6) =
        limite1y;

        resultado_seg(atualiza_linhas + nnos,7) =
        limite2y;

        %se for desejável salvar a imagem
        %segmentada do nó reenquadrado em tons de
        %cinza, descomentar a linha a seguir

        %imwrite(Asegm2(limite1x:limite2x,limite1y:limite2y,:),strcat(strcat(strcat
        ('E',num2str(alvo1020(k,1))),num2str(nnos)),'.bmp'));

        %se for desejável salvar a imagem
        % não segmentada do nó reenquadrado
        % colorida descomentar a linha a seguir

        %imwrite(AC(limite1x:limite2x,limite1y:limite2y,:),strcat(strcat(strcat('C'
        , num2str(alvo1020(k,1))),num2str(nnos)),'.bmp'));

        %se for desejável salvar a imagem colorida
        %segmentada do nó reenquadrado
        %descomentar a linha a seguir

        %imwrite(Asegm3(limite1x:limite2x,limite1y:limite2y,:),strcat(strcat(strcat
        ('B',num2str(alvo1020(k,1))),num2str(nnos)),'.bmp'));

        %se for desejável salvar a imagem
        % não segmentada do nó reenquadrado em tons
        %de cinza, descomentar a linha a seguir

        %imwrite(A(limite1x:limite2x,limite1y:limite2y,:),strcat(strcat(strcat('F',
        num2str(alvo1020(k,1))),num2str(nnos)),'.bmp'));

    else

        %mescla limites encontrados do mesmo nó se
        %o nó segmentado pertence à área do
        %anterior

        if(limite1x
        < resultado_seg(atualiza_linhas - 1 +
        nnos,4))

```

```

    resultado_seg(atualiza_linhas - 1 + nnos,4)
    = limite1x;
                                else

    limite1x = resultado_seg(atualiza_linhas -
    1 + nnos,4);
                                end
                                if(limite2x
< resultado_seg(atualiza_linhas - 1 +
nnos,5))

    resultado_seg(atualiza_linhas - 1 + nnos,5)
    = limite2x;
                                else

    limite2x = resultado_seg(atualiza_linhas -
    1 + nnos,5);
                                end
                                if(limite1y
< resultado_seg(atualiza_linhas - 1 +
nnos,6))

    resultado_seg(atualiza_linhas - 1 + nnos,6)
    = limite1y;
                                else

    limite1y = resultado_seg(atualiza_linhas -
    1 + nnos,6);
                                end
                                if(limite2y
< resultado_seg(atualiza_linhas - 1 +
nnos,7))

    resultado_seg(atualiza_linhas - 1 + nnos,7)
    = limite2y;
                                else

    limite2y = resultado_seg(atualiza_linhas -
    1 + nnos,7);
                                end

    atualiza_linhas = atualiza_linhas - 1;
end
else
    resultado_seg(atualiza_linhas + nnos,1) =
    alvo1020(k,1);
    resultado_seg(atualiza_linhas + nnos,2) =
    mediax;
    resultado_seg(atualiza_linhas + nnos,3) =
    mediay;
    resultado_seg(atualiza_linhas + nnos,4) =
    limite1x;
    resultado_seg(atualiza_linhas + nnos,5) =
    limite2x;
    resultado_seg(atualiza_linhas + nnos,6) =
    limite1y;
    resultado_seg(atualiza_linhas + nnos,7) =
    limite2y;

%se for desejável salvar a imagem

```

```

                                %segmentada do nó reenquadrado em tons de
                                %cinza, descomentar a linha a seguir

%imwrite(Asegm2(limite1x:limite2x,limite1y:limite2y,:),strcat(strcat(strcat(
('E',num2str(alvo1020(k,1))),num2str(nnos)),'.bmp')));

                                %se for desejável salvar a imagem
                                % não segmentada do nó reenquadrado
                                % colorida descomentar a linha a seguir

%imwrite(AC(limite1x:limite2x,limite1y:limite2y,:),strcat(strcat(strcat('C'
, num2str(alvo1020(k,1))),num2str(nnos)),'.bmp')));

                                %se for desejável salvar a imagem colorida
                                %segmentada do nó reenquadrado
                                %descomentar a linha a seguir

%imwrite(Asegm3(limite1x:limite2x,limite1y:limite2y,:),strcat(strcat(strcat(
('B',num2str(alvo1020(k,1))),num2str(nnos)),'.bmp')));

                                %se for desejável salvar a imagem
                                % não segmentada do nó reenquadrado em tons
                                %de cinza, descomentar a linha a seguir

%imwrite(A(limite1x:limite2x,limite1y:limite2y,:),strcat(strcat(strcat('F',
num2str(alvo1020(k,1))),num2str(nnos)),'.bmp'));
                                end
                                else
                                    nnos = nnos - 1;
                                end
                                else
                                    %se não há nó na imagem, anotar coordenadas com "0"
                                    if(contrl_tem_no == 0)
                                        resultado_seg(atualiza_linhas + 1,1) =
alvo1020(k,1);
                                        resultado_seg(atualiza_linhas + 1,2) = 0;
                                        resultado_seg(atualiza_linhas + 1,3) = 0;
                                        resultado_seg(atualiza_linhas + 1,4) = 0;
                                        resultado_seg(atualiza_linhas + 1,5) = 0;
                                        resultado_seg(atualiza_linhas + 1,6) = 0;
                                        resultado_seg(atualiza_linhas + 1,7) = 0;
                                    end
                                end
                                    y=y+1;
                                end
                                    x = x + 1;
                                end
                                    if(contrl_tem_no == 0)
                                        nnos = nnos + 1;
                                    end
                                end
                                    k = k + 1;
                                %imagem faltante na base
                                if (k == 133)
                                    k = 134;
                                end
                                end
end

```