

CLASSIFICAÇÃO DE MADEIRA SERRADA DE EUCALIPTO POR VISÃO ARTIFICIAL

JOSEPH K. KHOURY JUNIOR¹, FRANCISCO DE A. DE C. PINTO², CARLOS A. A. VARELLA¹, DANIELLE M. P. MATTAR³

¹ Engenheiro Agrícola, D.Sc., Prof. Adjunto, Depto.de Engenharia, UFRuralRJ, Seropédica-RJ, (21) 26821210, E-mail: kalil@ufrj.br.

² Engenheiro Agrícola, Ph.D., Prof. Adjunto, DEA, UFV, Viçosa - MG.

³Graduanda Engenharia Agrícola, UFRuralRJ, Seropédica-RJ.

Escrito para apresentação no
XXXV Congresso Brasileiro de Engenharia Agrícola
31 de julho a 4 de agosto de 2006 – João Pessoa - PB

RESUMO: Neste trabalho, foi desenvolvido e testado um algoritmo de um sistema de visão artificial para classificação de madeira serrada de eucalipto pela aparência de acordo com a norma brasileira NBR 14806. Um algoritmo foi implementado para identificação de blocos da imagem com defeitos e madeiras limpa, mensuração das dimensões dos defeitos e classificação das peças de madeira. O algoritmo foi testado em imagens de 20 faces largas de madeira serrada de eucalipto e apresentou exatidão global de 65% na classificação de cada peça, independentemente. Entretanto, a exatidão foi de 90% na classificação da peça, quando ambas as faces foram avaliadas simultaneamente. Os erros causados na classificação não foram devido à identificação de madeira limpa, mas principalmente na confusão entre alguns tipos de defeitos.

PALAVRAS-CHAVE: processamento de imagem, visão artificial, classificação de madeira.

CLASSIFICATION OF EUCALYPTUS SAWN LUMBER BY MACHINE VISION SYSTEM

ABSTRACT: An study was carried out to develop and test an algorithm of a machine vision system for classification of the eucalyptus sawn lumber based on appearance, according to the Brazilian norm NBR 14806. The algorithm was implemented for: identifying the image blocks of defects and clear wood, dimension measurements and board grading. The algorithm was tested on 20-face images of eucalyptus sawn lumber, and showed an overall accuracy of 65% in classification of each board face. However, an accuracy of 90% was attained in classification of the board, when both faces were simultaneously evaluated. The occurrence of errors in classification was not due to the identification of clear wood, but mainly because the embarrassment among some kinds of defects.

KEYWORDS: : image processing, machine vision, lumber grading.

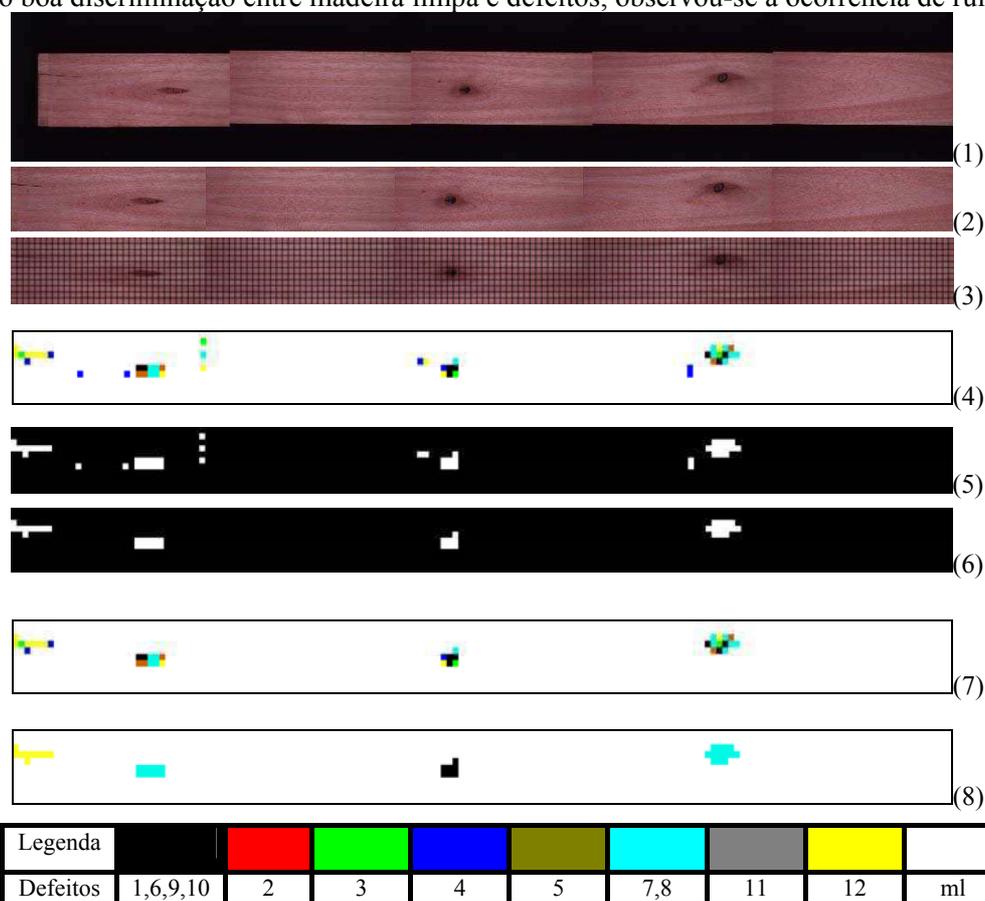
INTRODUÇÃO: O sistema de visão artificial (SVA) utiliza câmeras digitais, para adquirem as informações da energia eletromagnética refletida pelos objetos, para automatizar processos. Um SVA para inspeção de superfícies consiste das seguintes etapas: aquisição, processamento e análise de imagens (PHAM & ALCOCK, 1998). Na etapa de análise, a informação é transformada de imagem digital para expressões, que afetam a classificação da madeira serrada em: peça da classe A, peça descartada, dentre outros. Quando implementado na indústria, o SVA não apresenta o mesmo desempenho da etapa de desenvolvimento, degradando a exatidão da classificação. Em geral, este fato, ocorre por que os algoritmos desenvolvidos para estes sistemas não se ajustam às variações e imprevistos, que ocorrem no meio industrial. No entanto, esses sistemas têm se mostrado superiores à fraca exatidão da classificação realizada visualmente. Segundo Huber et al. (1985), em serrarias cuja classificação era visual obtiveram acerto médio de 68%. Provavelmente, um SVA é capaz de executar

esta tarefa, mesmo que não seja perfeito, com potencial para obter resultados melhores, além de não ser afetado pela fadiga ou outros fatores humanos. As câmeras coloridas, com fotossensores sensíveis nas bandas do vermelho (Vm), verde (Vd) e azul (Az), são um dos métodos de aquisição de imagens mais estudados por pesquisadores, em classificação de superfícies de madeiras (KLINE et al., 1998; HANEY et al., 1994). Essas pesquisas têm demonstrado que, ao utilizar o espaço de cor Vm, Vd e Az, obtém-se um melhor desempenho na classificação de madeiras, em comparação com as câmeras monocromáticas. Khoury Junior (2004) desenvolveu classificadores para identificação de defeitos em madeiras serradas de eucalipto, mencionadas na norma NBR 14806 (ABNT, 2002), utilizando características de percentis de imagens digitais. Os resultados indicaram que os classificadores desenvolvidos por redes neurais ou funções discriminantes paramétricas podem ser empregados na identificação de defeitos de madeiras serradas. Neste trabalho, objetivou-se desenvolver e testar um algoritmo para um sistema de visão artificial para classificação de madeira serrada de eucalipto pela aparência de acordo com as classes de qualidade mencionadas na norma NBR 14806 (ABNT, 2002).

MATERIAL E MÉTODOS: Foram amostradas dez peças de madeira serrada de eucalipto secas ao ar e previamente aplainadas. Para aquisição das imagens, foi utilizada a câmera colorida Duncantech, modelo MS3100. A altura da câmera foi de 0,9 m da superfície da face larga da peça de madeira serrada, sendo a resolução espacial foi de $0,24 \times 0,24 \text{ mm.pixel}^{-1}$. O sistema teve iluminação controlada utilizando lâmpadas halógenas instaladas em refletores. O algoritmo utilizado neste trabalho foi desenvolvido no Laboratório de Projeto de Máquinas e Visão Artificial do departamento de Engenharia Agrícola da Universidade Federal de Viçosa e implementado na plataforma do MatLab®, com o pacote de ferramentas para processamento de imagens. O objetivo final do desenvolvimento desse algoritmo foi transformar a informação de uma imagem digital, imagem das faces de madeira serrada, em uma informação de dados tabelados das quantidades de defeitos, em relação à madeira limpa, que servirão para classificar a peça em cinco classes de qualidade ou descartada das exigências mínimas de qualidade da regra de classificação adotada. O algoritmo foi desenvolvido, simulando-se a entrada de dados de uma imagem adquirida em uma esteira transportadora de fundo preto, contendo peça de madeira serrada. As etapas do algoritmo desenvolvido neste trabalho, desde a aquisição da imagem até a classificação final da peça foram divididas em três fases: pré-processamento, processamento e análise da imagem. As três primeiras etapas formaram a fase de pré-processamento, cujo objetivo era formar uma imagem da peça de madeira, subdividida em blocos de imagem, para a etapa de processamento. Inicialmente, as imagens são agrupadas até cobrir toda a extensão da face da peça, formando a 'imagem de madeira e fundo'. Em seguida, o fundo da imagem é retirado por meio de um algoritmo, desenvolvido para identificar as bordas da peça. Finalmente, ajustou-se a imagem em blocos de 32×32 pixels, para retirada de características de percentis, que representassem cada bloco no classificador de tipos de defeitos ou madeira limpa. As etapas de quatro a oito formaram a fase de processamento da imagem, cujo objetivo era formar uma imagem com os defeitos e madeira limpa identificados. Para classificar cada bloco da imagem, foi utilizada a função discriminante linear com escores das cinco primeiras variáveis canônicas desenvolvidas para blocos de 32×32 pixels por Khoury Junior (2004). Nas etapas cinco e seis, inicialmente, a imagem classificada por tipos de defeitos foi transformada em imagem binária: 0(zero) para madeira limpa e 1(um) para defeitos. Nas imagens binárias, foram aplicadas um algoritmo de identificação, rotulação e agrupamento dos blocos de valor um, em que cada agrupamento foi considerado um objeto (defeito). A rotina "BWLABEL" do MATLAB foi utilizada nessa etapa, sendo esta a implementação do algoritmo desenvolvido por Haralick & Shapiro (1992), citado por MATLAB (2000). Em seguida, foram eliminados os objetos que tinham dimensões inferiores a três blocos, sendo os mesmos assumidos como sendo pequenas irregularidades ou sujeiras da madeira limpa. Nas etapas sete e oito, realizou-se uma reclassificação dos objetos selecionados na etapa anterior. Assumindo-se que um objeto continha um mesmo tipo de defeito, este era classificado pela predominância do tipo de defeito dos blocos contidos naquele objeto. As etapas nove e dez formaram a fase de análise da imagem. Na etapa nove, foram extraídas as medidas das dimensões dos objetos, necessárias à classificação da peça com a rotina 'IMFEATURE' (MATLAB, 2000). Finalmente, na última etapa do algoritmo, foram implementadas as regras da norma adotada para inclusão da peça na classe de qualidade da madeira serrada. As regras para inclusão em uma classe de qualidade de

madeira são independentes por tipo de defeito. A face da peça foi classificada com base na regra de decisão do defeito que tiver a classe mais inferior. Na avaliação do algoritmo de classificação, as peças de madeira selecionadas foram classificadas, visualmente, em suas duas faces largas. Elaborou-se um relatório com os resultados da classificação por face. A classe da face pior é considerada a classe final da tábua, segundo a norma adotada. Das próprias madeiras serradas classificadas visualmente, foram adquiridas suas imagens, sendo as mesmas classificadas pelo programa desenvolvido, para comparação com os resultados classificados visualmente. Os resultados da classificação foram organizados em uma matriz de erro ou confusão, (CONGALTON, 1991), de dimensão igual ao número de classes das faces das peças e a classificação da peça considerando a sua pior face. No entanto, os resultados também são apresentados por face.

RESULTADOS E DISCUSSÃO: A Figura 1 ilustra todas as etapas de classificação de uma face de madeira de eucalipto. Na etapa quatro, realizou-se a classificação dos blocos, utilizando-se funções discriminantes obtidas de características de percentis do histograma da imagem. Apesar de nesta etapa ter havido boa discriminação entre madeira limpa e defeitos, observou-se a ocorrência de ruídos.



1 = bolsa de goma; 2 = esmoado; 3 = fendilhado; 4 = furos de inseto; 5 = medula; 6 = nó cariado; 7 = nó sadio; 8 = nó sadio corrompido; 9 = nó solto encaixado; 10 = nó solto oco; 11 = podridão; 12 = racha e ml = madeira limpa.

Figura 1 - Imagem peça de madeira e fundo (1); imagem peça (2); imagem subdividida (3); imagem classificada (4); imagem binária (5); imagem binária de blocos selecionados (6); imagem de classes de defeitos nos objetos selecionados (7); imagem de classes de defeitos predominantes nos objetos (8).

Esses ruídos foram blocos de madeiras limpas identificados como defeitos, que estavam desconectados e apresentavam pequenas sujeiras, manchas, variação da grã da madeira e variação da intensidade luminosa entre uma imagem e outra. Nas etapas cinco e seis, conseguiu-se eliminar aqueles blocos de madeira limpa classificados como defeitos e que, na verdade, eram ruídos, pois, os blocos que eram defeitos e foram classificados como defeitos estavam agrupados em mais de três blocos. Nas etapas sete e oito, após selecionados, os objetos maiores foram classificados, novamente,

pela predominância do defeito contido em seu interior, no qual minimizou-se o problema da confusão entre defeitos. No exemplo da Figura 1, da esquerda para direita, observa-se que os defeitos racha, nó sadio e nó cariado foram classificados corretamente. Entretanto, o nó solto encontrado na extremidade direita da peça apresentava coloração clara, em seu interior, motivo provável de ter sido confundido com outras classes de defeitos, nos quais predominou, neste objeto, o nó sadio. No resultado da matriz de confusão obteve o erro global de classificação por face de 35% e as maiores confusões ocorreram entre as classes quatro e cinco. Esses erros foram atribuídos à dificuldade em identificar alguns tipos de defeitos como furo de inseto e na confusão entre medula e nó sadio. A classificação da peça, baseada em sua pior face, conforme propõe a norma (ABNT, 2002), o erro na classificação final foi de 10%. Esta redução foi, provavelmente, devido à tendência de os mesmos defeitos estarem presentes em ambas as faces, aumentando a probabilidade de acerto do algoritmo. Por exemplo, nós e rachas estarão, normalmente, presentes nas duas faces, pois, atravessam a face estreita da peça, assim como os outros defeitos são característicos da posição à qual a peça de madeira foi extraída na tora, ou por injúrias causadas na mesma, que afetam, geralmente, as duas faces. Desta maneira, quando erroneamente classificava-se uma face para uma classe superior, devido à não identificação de um defeito, o algoritmo teria outra chance de identificar o mesmo defeito na outra face. Conseqüentemente, acertava a classe desta segunda face. Como a peça era classificada, baseando-se em sua pior face, acertava-se a classe da peça.

CONCLUSÕES: O algoritmo desenvolvido apresentou exatidão global de 65% na classificação de cada face da peça, independentemente. Entretanto, a exatidão global foi de 90% quanto à classificação da peça, em que ambas as faces foram avaliadas simultaneamente. A ocorrência de erros na classificação final da madeira serrada não foi devida à identificação de madeira limpa, mas, principalmente à confusão entre alguns tipos de defeitos. O algoritmo desenvolvido foi considerado satisfatório, para aplicação em sistemas automatizados de classificação de madeira serrada de eucalipto

REFERÊNCIAS BIBLIOGRÁFICAS

CONGALTON, R.G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote sensing of environment** n. 37 p. 35-46, 1991.

HANEY, L.; PRECETTI, C.; GIBSON, H.; KRUTZ, G.; CASSENS, D. Color matching of wood with a real-time machine vision system. **ASAE Paper No. 943579**, ASAE Meeting Presentation, St. Joseph, Michigan, 1994, 15 p.

HUBER, H. A.; McMILLIN, C. W.; McKINNEY, J. P. Lumber defect detection abilities of furniture rough mill employees. **Forest Products Journal**, 35(11/12), p. 79-82, 1985.

KLINE, D. E.; WIDOYOKO, A.; WIEDENBECK, J. K.; ARAMAN, P.A. Performance of color camera machine vision in automated furniture rough mil systems. **Forest Products Journal**, 48(3), p. 38-45, 1998.

MATLAB User's Guide, The **Math Works Inc.**, 2000.

PHAM, D.T.; ALCOCK, R.J. Automated grading and defect detection: a review. **Forest Products Journal**, 48(4), p34-42, 1998.

KHOURY JUNIOR, J.K. **Desenvolvimento e avaliação de um sistema de visão artificial para classificação de madeira serrada de eucalipto**, 2004.101f.. Dissertação (Doutorado em Engenharia Agrícola) – UFV, Viçosa, Minas Gerais, 2004.