

Redes neurais para reconhecimento de defeitos de
madeira serrada de eucalipto em imagens digitaisNeural networks for recognition of
eucalypts lumber defects in digital images¹Joseph Kalil Khoury Junior; ²Francisco de Assis de Carvalho Pinto;
³Daniel Marçal de Queiroz, ⁴Ricardo Marius Della Lucia e ⁵Ricardo Capúcio de Resende**Resumo**

As redes neurais artificiais (RNA) vêm sendo utilizadas em sistemas de visão artificial para identificação de classes de padrões em imagens. Neste trabalho, o objetivo foi desenvolver e avaliar RNAs para identificar classes de defeitos de madeira serrada de eucalipto em imagens digitais, utilizando-se como características os percentis das bandas do vermelho, verde e azul de câmeras coloridas. Foram comparadas diferentes arquiteturas e métodos de treinamento de RNAs. Os classificadores por RNAs foram considerados satisfatórios para identificação dos defeitos de madeira serrada de eucalipto, apresentando as maiores exatidões globais de 83,1 e 76,6%, dependendo do tamanho de blocos da imagem.

Palavras-chave: Processamento de imagem, Visão artificial, Classificação de madeira

Abstract

The artificial neural networks (ANN) have been used in the machine vision systems for identifying the pattern classes on images. The objective of this study was to develop and evaluate the ANNs in order to identify the defects of eucalypts sawn lumber in digital images, using the percentile of the red, green and blue bands in the color cameras as features. Different ANNs architectures and training methods were evaluated. The neural artificial network classifiers showed to be satisfactory for the identification of defects in eucalypts sawn lumber, because they presented the best overall accuracy of 83.1 and 76.6%, depending on the size of image blocks.

Keywords: Image processing, Machine vision, Lumber grading

INTRODUÇÃO

A indústria de madeira serrada tem dispensado especial atenção às etapas de classificação e seleção de peças de madeira. Estas etapas são, geralmente, realizadas por classificadores humanos. A etapa de classificação é considerada uma atividade estressante em razão da dificuldade dos classificadores realizarem as tarefas de identificação dos tipos de defeitos, medirem e graduarem a peça durante tempo prolongado.

Um sistema de visão artificial automatiza um processo, baseado nas informações adquiridas de imagens digitais. O sucesso deste sistema está no desenvolvimento de algoritmos de processamento e análise das imagens, capaz de gerar o sinal adequado para os atuadores eletromecânicos. Nesses algoritmos, geralmente são incorpo-

radas técnicas de inteligência artificial, sendo as redes neurais artificiais (RNAs) uma das técnicas mais utilizadas (PACKIANATHER e DRAKE, 2000; SARIGUL *et al.*, 2003).

Em comparação com classificadores estatísticos que determinam planos lineares ou quadráticos, o maior benefício de uma RNA é sua capacidade de determinar planos não-lineares de separação das classes (GONZALEZ e WOODS, 1992). No desenvolvimento de uma RNA, não há necessidade de assumir um tipo de função de distribuição para os dados, bem como existe a possibilidade de implementá-la em um sistema de processamento paralelo (PINTO *et al.*, 1999).

Kauppinen (1999) avaliou os defeitos de tábuas de *Pinus* por um classificador de k-vizinhos mais próximo, utilizando características de per-

¹Professor Adjunto - Instituto de Tecnologia - Departamento de Engenharia - Universidade Federal Rural do Rio de Janeiro - Seropédica, RJ - 23890-000 - E-mail: kalil@ufrj.br

²Professor Adjunto - Departamento de Engenharia Agrícola - Universidade Federal de Viçosa - Viçosa, MG - 36570-000 - E-mail: facpinto@ufv.br

³Professor Adjunto - Departamento de Engenharia Agrícola - Universidade Federal de Viçosa - Viçosa, MG - 36570-000 - E-mail: queiroz@ufv.br

⁴Professor Adjunto - Departamento de Engenharia Florestal - Universidade Federal de Viçosa - Viçosa, MG - 36570-000 - E-mail: rdlucia@ufv.br

⁵Professor Adjunto - Departamento de Engenharia Florestal - Universidade Federal de Viçosa - Viçosa, MG - 36570-000 - E-mail: ricardocapucio@ufv.br

centis do histograma das bandas vermelho (Vm), verde(Vd) e azul(Az). Na análise de exatidão em uma amostra de 2834 observações de seis tipos de defeitos, o autor obteve um erro de classificação de 34%. Concluiu-se que as características de percentis são simples de calcular, possuem boa capacidade discriminante de defeitos de madeira e são convenientes para implementação em tempo real. O alto nível de erro foi atribuído à dificuldade em definir algumas classes de defeitos da amostra como, por exemplo, o nó solto é uma subcategoria do nó morto.

Uma RNA é composta por um conjunto de elementos computacionais (neurônio artificial), que relacionam os valores de saída e entrada por meio da seguinte expressão:

$$y^{ij} = f\left(\sum_{i'=1}^n y^{i'(j-1)} w_{i',ij} + b^{ij}\right)$$

em que, y_{ij} é a saída do neurônio i da camada j ; n é o número de neurônios da camada anterior; $y^{i'(j-1)}$ é a saída do neurônio i' da camada anterior; $w_{i',ij}$, é o peso sináptico do neurônio i da camada j , ativado pelo neurônio i' da camada anterior; b^{ij} é a compensação do neurônio i da camada j ; f é a função de ativação do neurônio i .

O desenvolvimento de uma RNA consiste em determinar sua arquitetura, isto é, os números de camadas e de neurônios em cada camada, bem como ajustar os seus parâmetros w 's e b 's, fase esta conhecida como treinamento. A arquitetura varia de acordo com a complexidade do problema e não pode ser definida a priori ao treinamento. Um dos algoritmos mais utilizados para treinamento de uma RNA é o de retropropagação de erro (HAYKIN,1999; MATLAB, 2000), em que o ajuste dos parâmetros é realizado por método iterativo de minimização do erro quadrático médio (EQM) entre os valores calculados e aqueles esperados na saída.

No desenvolvimento de uma RNA, deve-se sempre ter em mente o poder de generalização da mesma, pois, caso contrário, a rede pode apresentar baixos erros com a amostra de treinamento e altos níveis de erro com valores não-utilizados no ajuste dos parâmetros. Esta 'memorização' da amostra de treinamento pode ocorrer devido a um número elevado de iterações ou a uma arquitetura superdimensionada.

Para o desenvolvimento de uma RNA, uma amostra da população é coletada. Esta amostra é dividida em duas partes: uma para treinamento e a outra para teste, em que se avalia o erro de classificação da RNA. O método de 'parada mais

cedo' utiliza parte da amostra de treinamento para interromper a atualização dos parâmetros livres e, assim, evitar a 'memorização'. Neste método, a parada ocorre quando se detecta um aumento do EQM na amostra utilizada para interromper o treinamento (HAYKIN, 1999). O número de iterações utilizadas para confirmar a tendência a aumento do EQM é dependente do problema (PRECHELT, 1998). Uma desvantagem deste método é quando se tem uma amostra para desenvolvimento de uma RNA com número reduzido de observações, pois, com a 'parada mais cedo', reduzirá ainda mais o número de observações para treinamento e teste.

Uma das maneiras utilizadas para melhorar a estimativa do erro de classificação, sem diminuir o tamanho da amostra de treinamento, é a validação cruzada (PRECHELT, 1998; HAYKIN, 1999). Neste método, a amostra é dividida em n partes, mas somente uma das partes é reservada para teste. As outras $(n-1)$ partes restantes serão utilizadas no treinamento. Para uma mesma arquitetura, realiza-se o treinamento n vezes e o erro de classificação é avaliado pela soma dos erros encontrados nas observações, quando estas ficaram de fora do treinamento.

Neste trabalho, o objetivo foi desenvolver e avaliar RNAs para discriminar defeitos de madeiras serradas de eucalipto em imagens digitais, utilizando-se como características os percentis das bandas do vermelho, verde e azul de câmeras coloridas.

MATERIAL E MÉTODOS

Foram amostradas 40 peças de madeira serrada de eucalipto secas ao ar e previamente aplainadas, provenientes do Laboratório de Propriedades Físicas e Mecânicas da Madeira da UFV. As amostras foram escolhidas de forma que estariam presentes, além de madeiras limpas de coloração mais clara ou mais escura, com ou sem alburno, bem como os defeitos visuais mencionados na Associação Brasileira de Normas Técnicas (ABNT) – NBR 14806: (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 e (12) racha.

Para aquisição das imagens, foi utilizada a câmera colorida Duncantech, modelo MS3100, conectada a um computador por meio de uma placa de aquisição de vídeo National Instruments, modelo PCI 1424. A altura da câmera foi

de 0,9 m da superfície da peça da madeira e a resolução espacial foi de 0,24 x 0,24 mm por pixel. O sistema foi iluminado com duas lâmpadas halógenas de 300 w instaladas em refletores com difusor de luz. Na superfície da face da madeira, o iluminamento foi de 2500 lux.

As imagens das madeiras serradas, com 1392 pixels na horizontal e 1039 pixels na vertical, foram adquiridas nas suas duas faces. Feita a varredura das faces da madeira serrada, obtiveram-se 594 imagens; destas, foram cortados blocos que representaram as classes de defeito e madeira limpa, obtendo-se a seguinte amostra: 41 de madeira limpa de alburno, 48 de madeira limpa clara, 24 de madeira limpa clara áspera, 74 de madeira limpa escura, 25 de bolsa de goma, 9 de esmoado, 16 de fendilhado, 34 de furos de inseto, 54 de medula, 46 de nó cariado, 34 de nó sadio, 29 de nó sadio corrompido, 28 de nó solto encaixado, 9 de nó solto oco, 5 de podridão e 16 de racha. As madeiras limpas foram subdivididas em três tipos diferentes na intenção de melhor descrever a amostra. Porém, no desenvolvimento do classificador foram consideradas pertencentes à mesma classe.

Dois tamanhos de blocos de imagens de 64x64 e 32x32 pixels foram comparados. Na Figura 1 são mostrados exemplos de blocos de imagens que representam as classes de defeitos e madeira limpa estudadas.

Características das imagens

As características retiradas de cada bloco de imagens foram 12 percentis das bandas Vm, Vd e Az, construindo, assim, um vetor de 36 características. Utilizaram-se os percentis de 2, 5, 10, 20, 30, 40, 50, 60, 70, 80, 90 e 95 %. A diferença entre os percentis 2 e 95% foi utilizada para normalizar o vetor:

$$C_{Bd}^y = \frac{P_{Bd}^y}{P_{Bd}^{95\%} - P_{Bd}^{2\%}}$$

em que C_{Bd}^y = característica normalizada do percentil y na banda Bd; P_{Bd}^y = nível de cinza da banda Bd do percentil y; y = 2, 5, 10, 20, 30, 40, 50, 60, 70, 80, 90, 95 %; e Bd = bandas Vm, Vd e Az.

A partir do vetor de características originais foi realizado o teste de médias T^2 de Hotelling para verificar se a separação entre as classes de interesse foi significativa, ao nível de 0,01. O teste T^2 de Hotelling da estatística multivariada corresponde ao teste t de Student no campo univariado. A distribuição da estatística T^2 de Hotelling pode ser transformada por um valor correspondente à distribuição da estatística F. O valor de F transformado, conhecido por F_0 , é calculado por $F_0 = ((n_1+n_2-p-1)/(n_1+n_2-2)p)T^2$, no qual T^2 é a função de distribuição, n_1 e n_2 são os números de observações das classes comparadas, p é o número de características. O valor F_0 calculado pode ser comparado com a distribuição F tabelada, que é função de $F_{\infty, p, n_1+n_2-p-1}$ (REGAZZI, 2000).

A diferença significativa entre as médias não implica, necessariamente, em boa classificação. A eficácia de um método de classificação pode ser avaliada, independentemente de qualquer teste de médias. Por outro lado, se a diferença não for significativa, a procura de uma regra de classificação seria, provavelmente, infrutífera (REGAZZI, 2000).

Após o teste de médias, foi realizado o descarte de características pelo método passo-a-passo (stepwise). Neste método, o poder das características em identificar as classes foi avaliado pelo critério de Wilks Lambda, usando-se um nível de significância de 0,15. O procedimento STEPDISC do programa computacional SAS foi utilizado para esta tarefa (SAS, 1999). As características escolhidas pelo método passo-a-passo definiram a dimensão do vetor de variáveis para treinar e avaliar as RNAs.




Figura 1. Exemplo de blocos de imagens de 64x64 pixels de (ml) madeira limpa, (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 e (12) racha. (Sample of image blocks of 64x64 pixels of (ml) clear wood, (1) pitch pocket, (2) wane, (3) seasoning check, (4) insect holes, (5) pith, (6) unsound knot, (7) sound knot, (8) rotten sound knot, (9) encased loose knot, (10) loose knot, (11) decay and (12) splits)

Classificador por redes neurais artificiais

Neste trabalho foram desenvolvidas RNAs por dois métodos de treinamento e teste. No primeiro, o treinamento foi por 'parada mais cedo' e o teste foi por validação cruzada, dividindo-se a amostra em quatro partes iguais. Devido à agilidade de treinamento e teste, este método foi utilizado para determinar as melhores arquiteturas das RNAs. Entretanto, uma parte da amostra é reservada para parada das iterações, que tem a desvantagem de reduzir o tamanho da amostra para treinamento. Com isto, pode ficar comprometida a representatividade da amostra no treinamento.

Um segundo método de desenvolvimento de RNAs teve a finalidade de reduzir o problema de tamanho da amostra. Neste, a parada do treinamento foi interrompida por um número definido de iterações. O teste foi por validação cruzada, pelo método 'deixando um de fora'. Desta forma, teve-se a vantagem de perder apenas uma observação para o treinamento. No entanto, para acessar o erro de classificação, foi

necessário realizar um número de treinamentos igual ao tamanho da amostra.

As arquiteturas das RNAs propostas foram do tipo $n_1-n_1-n_2-n_o$, isto é, n_1 é o número de variáveis da camada de entrada, n_1 e n_2 são números de neurônios nas camadas escondidas e n_o número de neurônios na camada de saída. O número de variáveis da camada de entrada correspondeu à dimensão do vetor de características, enquanto o número de neurônios da camada de saída foi igual ao número de classes de defeitos e madeira limpa a serem discriminados. As funções de ativação, utilizadas nos neurônios das camadas escondidas, foram tangente hiperbólica sigmóide, que apresentam resultados entre menos um e mais um, ao passo que, as funções da camada de saída foram logística sigmóide, que apresentam resultados entre zero e um. Desta maneira, uma vez apresentado à RNA um vetor de características de entrada, este era classificado para a classe de defeito ou madeira limpa, cujo neurônio da camada de saída tivesse valor mais próximo da unidade (Figura 2).

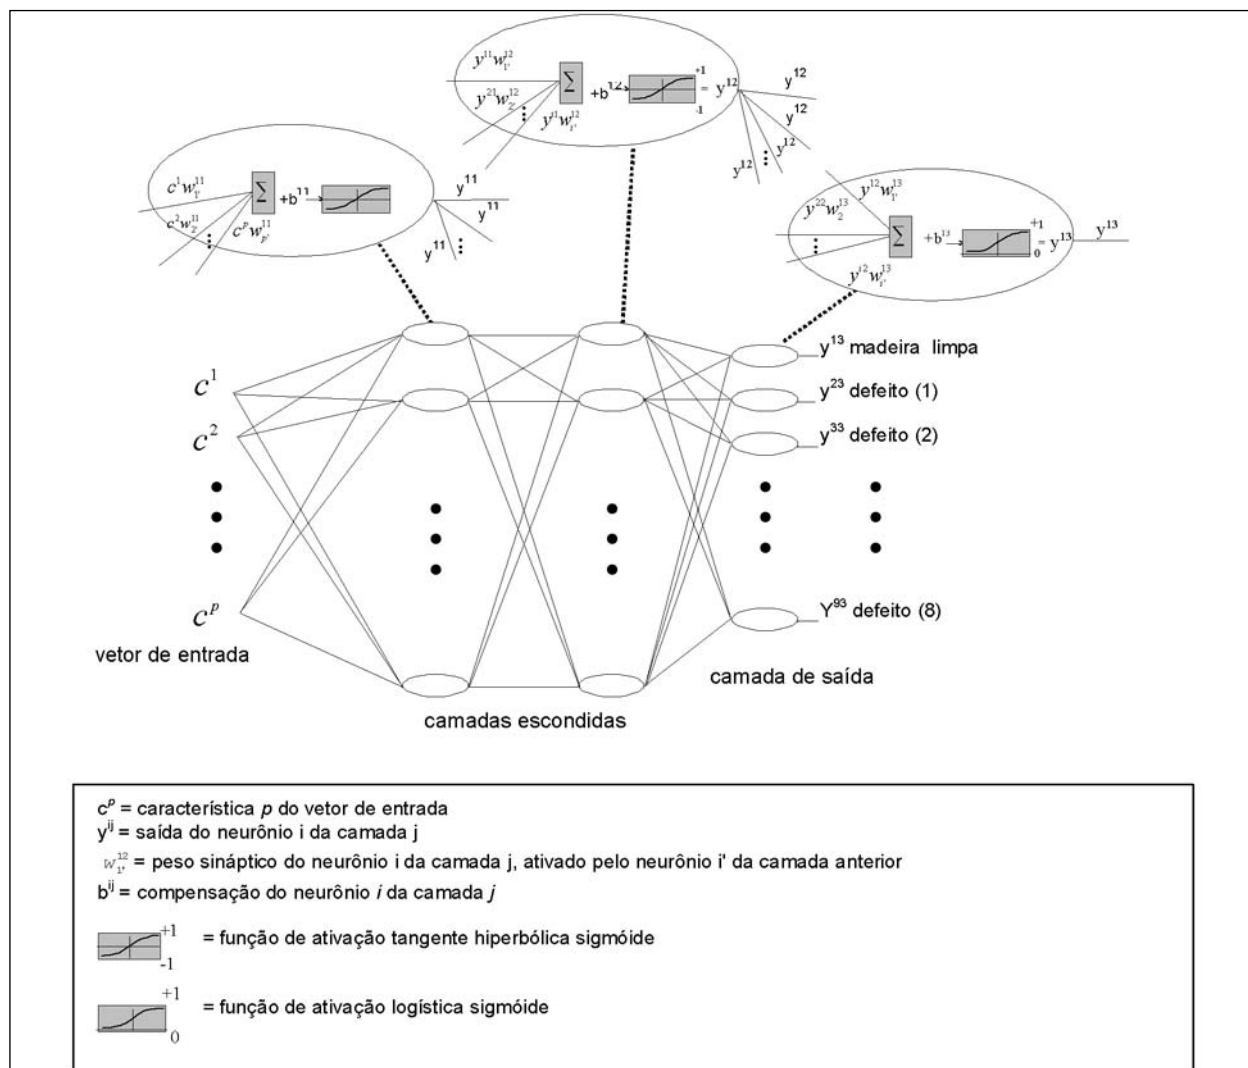


Figura 2. Arquitetura da rede neural artificial proposta para classificação de defeitos de madeira serrada de eucalipto. (Architecture of proposed artificial neural networks for recognition of eucalypts lumber defects)

As arquiteturas das redes comparadas foram 28 combinações de n_1 e n_2 : 26-26; 26-24; 26-22; 26-20; 26-18; 26-16; 26-14; 24-24; 24-22; 24-20; 24-18; 24-16; 24-14; 22-22; 22-20; 22-18; 22-16; 22-14; 20-20; 20-18; 20-16; 20-14; 18-18; 18-16; 18-14; 16-16; 16-14; 14-14.

As redes foram treinadas, utilizando-se o pacote de ferramentas do programa computacional Matlab® (MathWorks, Inc.). O algoritmo de retropropagação do erro foi utilizado para minimização do erro quadrático médio (EQM) entre a resposta obtida de uma RNA e a resposta esperada. A minimização foi realizada por método iterativo, em que os parâmetros livres da RNA (w 's e b 's) foram ajustados por meio de um gradiente, que dá a direção de decrescimento do EQM para cada iteração.

Existem diversos métodos para encontrar este gradiente. A escolha do método influi principalmente no tempo de treinamento, que é função do número de iterações para convergência e do esforço no processamento computacional para cálculo do gradiente. Os métodos padrões de minimização, que utilizam diferenciação dos parâmetros para cálculo do gradiente, em ordem crescente do esforço computacional, são: os do gradiente, que utilizam derivada de primeira ordem; os de gradiente conjugado, que utilizam derivadas de primeira ordem conjugadas ou ortogonais; os quase-newton ou secante, que utilizam uma aproximação da inversa da matriz hessiana e o de Newton, que utiliza a inversa da matriz hessiana, composta de segundas derivadas (MATEUS e LUNA, 1986).

Neste trabalho foi utilizado o método de minimização do erro 'uma etapa secante', que utiliza a função "TRAINOSS" do programa Matlab®. Este é uma variante do método quase-newton, em que a matriz hessiana é utilizada sem a necessidade de calcular sua inversa, sendo este o maior motivo de seu melhor desempenho, colocando-o entre os métodos do gradiente conjugado e quase-newton quanto ao esforço computacional (MATLAB, 2000).

O primeiro método de desenvolvimento das RNAs proposto neste trabalho foi por 'parada mais cedo', em que se utiliza uma parte da amostra não vista no treinamento, a fim de parar as atualizações dos parâmetros livres da RNA. Desta maneira, o EQM foi calculado nesta parte separada da amostra para cada iteração. Depois de detectado um aumento do EQM, os parâmetros da rede foram, ainda, atualizados por mais um número pré-definido de iterações,

e se dentro deste limite pré-definido o EQM voltasse a decrescer o treinamento seguiria normalmente, caso contrário ele pararia. Neste trabalho foram comparadas cinco, 100, 200, 400, 600 e 800 atualizações após a detecção do aumento do EQM antes que fosse realizada a parada do treinamento. Tendo em vista que no início do treinamento os parâmetros livres foram gerados aleatoriamente e que esses valores iniciais podem influenciar o resultado final do treinamento, cada arquitetura foi treinada cinco vezes. Dentre essas cinco RNAs treinadas, foi selecionada a que apresentou menor erro de classificação na amostra de teste.

Para acessar o erro de classificação de cada arquitetura comparada, aplicou-se o método de validação cruzada. A amostra foi dividida em quatro partes (A1, A2, A3 e A4) de tal maneira que cada parte tivesse observações de todas as classes. Duas partes foram utilizadas para treinamento, sendo uma para parada das iterações e outra para teste. Para cada arquitetura, realizaram-se quatro treinamentos e quatro testes (Tabela 1). O erro de classificação foi determinado, somando-se os erros obtidos com as amostras de teste.

Tabela 1. Esquema das amostras utilizadas para treinamento, parada e teste das RNAs no método 'parada mais cedo'. (Scheme of the samples used to train, stop and test of ANNs using early stop method)

	Treinamento	Parada	Teste
Rede 1	A2, A3	A1	A4
Rede 2	A1, A4	A2	A3
Rede 3	A1, A4	A3	A2
Rede 4	A2, A3	A4	A1

O segundo método de treinamento e teste de RNAs, utilizado neste trabalho, foi com treinamento por limite de iterações e teste pelo método 'deixando um de fora'. Este método é uma variante da validação cruzada, sendo utilizado quando a amostra tem número reduzido de observações (HAYKIN, 1999). Para cada treinamento, fica somente uma observação de fora para teste. Assim, consegue-se um maior número de observações na amostra de treinamento. As arquiteturas das RNAs que apresentaram melhores resultados pelo método de treinamento por 'parada mais cedo' foram utilizadas no treinamento deste método. Os números de iterações utilizadas nos treinamentos foram 500, 1000, 2000, 5000 e 8000. Tendo em vista que, no início do treinamento, os parâmetros livres foram gerados aleatoriamente e que esses valores iniciais podem influenciar o resultado final

do treinamento, cada arquitetura foi treinada três vezes. Entre essas três RNAs treinadas, selecionava-se aquela com menor erro de classificação na observação de teste.

Avaliação dos classificadores

Partindo-se da amostra de teste, os resultados da classificação foram avaliados em uma matriz quadrada de dimensão igual ao número de classes, denominada matriz de erro ou confusão (CONGALTON, 1991). Esta matriz permite calcular os erros de omissão, de comissão e o global, bem como as exatidões.

Uma maneira simples de avaliar um grupo de classificadores é por meio do erro global. Entretanto, este erro independe dos erros de omissão e comissão, que são importantes na avaliação de um classificador. Cohen (1960), citado por Rosenfield e Fitzpatrick-Lins (1986), desenvolveu um método de avaliação denominado coeficiente Kappa, que na comparação entre classificadores envolvem estes erros. O coeficiente Kappa é definido de acordo com a equação:

$$\hat{K} = \frac{P_o - P_c}{1 - P_c}$$

em que, \hat{K} = estimativa do coeficiente Kappa; P_o = proporção de unidades corretamente classificadas; P_c = proporção esperada de acerto por acaso,

$$P_o = \frac{1}{n} \sum_{i=1}^k x_{ii}; P_c = \frac{1}{n^2} \sum_{i=1}^k x_{i+} x_{+i}$$

x_{ii} = valor na linha i e coluna i da matriz de erros; x_{i+} = total da linha i ; x_{+i} = total da coluna i ; n = número total da amostra; e k = número total de classes.

Citados pelos mesmos autores, para comparar dois coeficientes Kappa independentes, pode-se utilizar o teste Z a um determinado nível de significância, que é calculado por:

$$Z = \frac{\hat{K}_1 - \hat{K}_2}{\sqrt{\text{var}(\hat{K}_1) + \text{var}(\hat{K}_2)}}$$

em que, Z é padronizado e normalmente distribuído; $\text{var}(\hat{K}_j)$ é a estimativa da variância do coeficiente Kappa.

Hudson e Ramm (1987) apresentam a formulação da variância desenvolvida originalmente por Cohen (1960) citado por Rosenfield e Fitzpatrick-Lins (1986):

$$\text{var}(\hat{K}) = \frac{1}{n} \left[\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2-\theta_2)}{(1-\theta_2)^3} + \frac{(1-\theta_2)^2(\theta_4-4\theta_2^2)}{(1-\theta_2)^4} \right]$$

em que,

$$\theta_1 = \frac{1}{n} \sum_{i=1}^c x_{ii}; \theta_2 = \frac{1}{n^2} \sum_{i=1}^c x_{i+} x_{+i}; \theta_3 = \frac{1}{n^2} \sum_{i=1}^c x_{ii}(x_{i+} x_{+i}); e$$

$$\theta_4 = \frac{1}{n^3} \sum_{i=1}^c \sum_{j=1}^c x_{ij}(x_{j+} x_{+i})^2;$$

O coeficiente Kappa pode ser estimado para cada classe individual, empregando-se a equação citada por Rosenfield e Fitzpatrick-Lins (1986), podendo ser calculada referente ao erro de omissão ou comissão. Neste trabalho o Kappa por classe foi avaliado em relação ao erro de omissão dado por:

$$\hat{K}_c = \frac{nx_{ii} - x_{i+} x_{+i}}{nx_{+i} - x_{i+} x_{+i}}$$

em que, \hat{K}_c = coeficiente Kappa por classe.

As arquiteturas das redes, os métodos de treinamento e o tamanho de blocos da imagem foram comparados utilizando-se o coeficiente Kappa, com o teste Z a um nível de significância de 5%.

RESULTADOS E DISCUSSÃO

A Tabela 2 apresenta os valores de F_o , calculado para o teste T2 de Hotelling dos vetores de médias das classes de defeitos e madeira limpa estudados, para os dois tamanhos de blocos de imagens. As diferenças entre as médias das classes 1, 6, 9 e das classes 7 e 8 não foram significativas ($p > 0,01$). Segundo a norma de classificação de madeira serrada de eucalipto (ABNT, 2002), os defeitos 1, 6, 9 e 10 são igualmente quantificados e pontuados para definição das classes de qualidade das peças, assim como os defeitos 7 e 8. Deste modo, pôde-se agrupar estes defeitos sem causar prejuízo na classificação final da peça.

A Tabela 3 apresenta os resultados do teste T² de Hotelling dos vetores de médias após o agrupamento das classes 1, 6, 9 e 10, bem como das classes 7 e 8 para dois tamanhos de blocos. Os resultados das diferenças entre as médias destas novas classes foram significativos ($p < 0,01$). Portanto, o desenvolvimento de um classificador para discriminar essas classes é viável.

Os resultados do descarte de características pelo método passo-a-passo são apresentados na Tabela 4. Para características retiradas de blocos de 64x64 pixels, ocorreu redução de 36 para 21 variáveis. Para blocos de 32x32 pixels, resultou uma redução de 36 para 18 variáveis. Estes resultados demonstraram a dificuldade de se utilizar uma câmera com apenas uma banda espectral na classificação de madeiras, pois, mesmo após o descarte, as características de todas as bandas contribuem para discriminar as classes.

Tabela 2. Valores de Fo calculado para o teste T² de Hotelling das 12 classes de defeitos e madeira limpa usando blocos de imagens de 64x64 pixels (acima da diagonal principal) e para blocos de 32x32 (abaixo da diagonal principal). (Values of Fo for T²-Hotelling test of 12 defect classes and clear wood using image blocks of 64x64 pixels (above the main diagonal) and 32x32 pixels (below the main diagonal))

classe	1	2	3	4	5	6	7	8	9	10	11	12	ml
1	-	5,32	5,05	5,69	3,39	1,18 ^{ns}	3,96	2,74	1,18 ^{ns}	2,61	3,72	6,76	14,69
2	3,51	-	7,05	5,42	6,31	5,14	4,41	4,55	5,77	3,66	6,00	7,52	6,87
3	8,23	7,62	-	4,58	4,25	6,44	5,04	3,95	4,96	5,46	3,67	2,33	12,06
4	6,81	6,61	5,96	-	5,48	5,72	2,91	2,99	5,17	3,98	4,05	4,67	5,14
5	3,63	5,36	6,47	4,58	-	5,94	3,25	2,90	4,15	3,97	5,04	6,61	19,69
6	2,5	3,28	10,09	7,89	5,86	-	4,12	2,83	1,49 ^{ns}	1,99	4,15	7,74	21,01
7	5,5	4,62	7,57	4,00	2,76	4,96	-	0,73 ^{ns}	3,92	3,23	4,28	5,33	9,41
8	4,11	4,82	4,29	2,12	1,86	4,26	1,65 ^{ns}	-	2,91	3,01	3,94	4,46	9,89
9	1,41 ^{ns}	4,18	7,09	5,07	2,53	1,83	3,65	2,28	-	2,39	3,93	6,00	16,16
10	3,68	4,26	7,47	5,7	4,73	2,36	4,37	4,17	3,13	-	3,98	5,45	6,99
11	2,88	3,6	3,75	2,43	2,41	3,31	2,54	2,43	2,63	3,60	-	3,89	5,70
12	7,91	6,34	3,83	6,02	6,04	9,34	6,59	3,98	6,9	7,05	3,20	-	11,12
ml	12,34	6,97	12,4	7,55	11,77	17,47	6,67	7,73	10,33	6,92	2,28	10,23	-

Fo = valor calculado da estatística F correspondente a estatística T² de Hotelling.

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.

Classes i de uma linha e j de uma coluna não diferem (p>0,01) se o valor de Fo(i,j) é seguido de ns.

Tabela 3. Valores de Fo calculado para o teste T² de Hotelling das oito classes de defeitos e madeira limpa usando blocos de imagens de 64x64 pixels (acima da diagonal principal) e para blocos de 32x32 (abaixo da diagonal principal). (Values of Fo for T²-Hotelling test of eight defect classes and clear wood using image blocks of 64x64 pixels (above the main diagonal) and 32x32 pixels (below the main diagonal))

classe	1/6/9/10	2	3	4	5	7/8	11	12	ml
1/6/9/10	-	5,91	7,05	7,83	7,25	6,97	4,31	8,71	40,30
2	3,92	-	6,89	5,41	6,21	4,92	5,98	7,43	6,90
3	10,56	7,32	-	4,47	4,22	5,20	3,69	2,32	11,84
4	9,45	6,47	5,89	-	5,39	3,74	4,06	4,65	5,14
5	5,98	5,21	6,29	4,54	-	4,11	5,08	6,60	19,47
7/8	7,75	4,98	6,59	3,55	2,52	-	4,39	5,74	16,35
11	3,15	3,54	3,7	2,43	2,43	2,55	-	3,91	5,69
12	10,09	6,14	3,85	6,02	5,96	5,94	3,18	-	11,02
ml	30,11	6,85	11,89	7,35	11,57	11,38	2,27	9,91	-

Fo = valor calculado da estatística F correspondente a estatística T² de Hotelling.

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.

Classes i de uma linha e j de uma coluna não diferem (p>0,01) se o valor de Fo(i,j) é seguido de ns.

Tabela 4. Características selecionadas pelo método passo-a-passo para os blocos da imagem de 64x64 e 32x32 pixels. (Selected features by the stepwise method for image blocks of 64x64 and 32x32 pixels)

Blocos	Características ¹
64x64	C ² _{Vm} , C ¹⁰ _{Vm} , C ³⁰ _{Vm} , C ⁶⁰ _{Vm} , C ⁷⁰ _{Vm} , C ⁹⁰ _{Vm} , C ⁵ _{Vd} , C ¹⁰ _{Vd} , C ⁴⁰ _{Vd} , C ⁶⁰ _{Vd} , C ⁷⁰ _{Vd} , C ⁹⁵ _{Vd} , C ⁵ _{Az} , C ¹⁰ _{Az} , C ³⁰ _{Az} , C ⁴⁰ _{Az} , C ⁵⁰ _{Az} , C ⁶⁰ _{Az}
32x32	C ⁵ _{Vm} , C ¹⁰ _{Vm} , C ²⁰ _{Vm} , C ³⁰ _{Vm} , C ⁹⁵ _{Vm} , C ⁵ _{Vd} , C ²⁰ _{Vd} , C ³⁰ _{Vd} , C ⁶⁰ _{Vd} , C ⁷⁰ _{Vd} , C ⁸⁰ _{Vd} , C ² _{Az} , C ⁵ _{Az} , C ¹⁰ _{Az} , C ²⁰ _{Az} , C ⁴⁰ _{Az} , C ⁶⁰ _{Az} , C ⁷⁰ _{Az}

¹C_{Bd}^y = $\frac{P_{Bd}^y}{p_{Bd}^{95\%} - p_{Bd}^{2\%}}$; C_{Bd}^y = característica normalizada do percentil y na banda Bd; P_{Bd}^y = nível de cinza da banda Bd do percentil y; y = 2, 5, 10, 20, 30, 40, 50, 60, 70, 80, 90, 95 %; e Bd = bandas Vm, Vd e Az.

Classificadores de Redes Neurais

As Tabelas 5, 6 e 7 apresentam os resultados da comparação do tamanho de arquiteturas e métodos de treinamento de RNAs para características de blocos de 64x64 pixels.

Na Tabela 5 são apresentados os coeficientes Kappa global, variando-se o número de neurônios nas camadas escondidas. Somente foram

significativas as diferenças do coeficiente Kappa das arquiteturas 21-24-18-9, 21-24-16-9 e 21-20-18-9 com a arquitetura 21-20-16-9. Entretanto, os resultados mostraram que não houve diferenças significativas entre as redes de maior e as de menor número de neurônios escondidos. Por exemplo, a diferença do Kappa entre as arquiteturas 21-14-14-9 e 21-26-26-9 não foi significativa.

Tabela 5. Coeficiente Kappa global, em porcentagem, para o método de treinamento 'parada mais cedo' das diferentes RNAs (21-n₁-n₂-9)¹, para blocos de imagens de 64x64 pixels. (Overall Kappa Coefficient, in percentage, for the early stop method training for different ANNs (21-n₁-n₂-9)¹ using images blocks of 64x64 pixels)

n ₁	n ₂						
	26	24	22	20	18	16	14
26	63,7ab	60,4ab	61,2ab	60,5ab	61,5ab	64,2ab	60,0ab
24		63,5ab	61,1ab	61,2ab	59,1 b	59,6 b	60,8ab
22			62,7ab	60,3ab	63,2ab	61,7ab	61,1ab
20				62,3ab	59,1 b	65,3a	60,3ab
18					60,1ab	60,1ab	60,1ab
16						60,4ab	62,1ab
14							63,6ab

¹ = número de neurônios nas camadas de entrada, intermediárias e saída, respectivamente. Coeficientes Kappa seguidos de mesma letra, não diferem entre si pelo teste Z, ao nível de 5 %.

Na Tabela 6 são apresentados os coeficientes Kappa globais dos diferentes números de iterações para a interrupção do treinamento no método de 'parada mais cedo', para diferentes arquiteturas de RNA. Somente cinco iterações não foram suficientes para encontrar o melhor ajuste da RNA. No entanto, de 100 a 800 iterações não houve diferenças significativas do valor de Kappa. Portanto, 100 iterações foram suficientes para qualquer uma das arquiteturas comparadas.

Como não houve diferenças significativas quanto ao efeito das arquiteturas e que arquiteturas mais simples possuem maior capacidade de generalização e demandam menor esforço computacional, o número de neurônios escolhidos para ambas as camadas escondidas foi 14.

Na Tabela 7 são apresentados os resultados do coeficiente Kappa global, variando-se o número de iterações no método 'deixando um de fora'. Mil iterações foram suficientes para obter o ajuste da RNA, pois, o mesmo não diferiu significativamente do maior coeficiente Kappa obtido, quando o treinamento foi realizado com 2000 iterações.

As Tabelas 8, 9 e 10 apresentam os resultados da comparação do tamanho de arquiteturas e métodos de treinamento de RNAs para características de blocos de 32x32 pixels.

Não foram obtidas diferenças significativas dos coeficientes Kappa em comparações múltiplas dos tamanhos de arquitetura (Tabela 8). Assim, analogamente ao observado para blocos de 64x64 pixels, o número de neurônios escolhidos para as camadas escondidas foi 14.

Conforme se observa na Tabela 9, ao variar o número de iterações para interrupção de treinamento no método 'parada mais cedo', verificou-se que o número de 100 iterações não diferiu, estatisticamente, dos melhores resultados para as arquiteturas comparadas. Portanto, 100 iterações foram suficientes para este tamanho de bloco, independentemente da variação da arquitetura.

Tabela 7. Coeficiente Kappa global, em porcentagem, segundo treinamento pelo método 'deixando um de fora' com diferentes números de iterações, da RNA (21-14-14-9)¹ e blocos de imagens de 64x64 pixels. (Overall Kappa coefficient, in percentage, trained by leave-one-out method with different epoch numbers, of ANNs (21-14-14-9)¹ and images blocks of 64x64 pixels)

Iterações	Kappa global
500	71,2 b
1000	75,2 a b
2000	77,8 a
5000	75,4 a b
8000	76,1 a b

¹ = número de neurônios nas camadas de entrada, intermediárias e saída, respectivamente. Coeficientes Kappa global seguidos de mesma letra, não diferem entre si pelo teste Z, ao nível de 5 %.

Tabela 6. Coeficiente Kappa global, em porcentagem, para o método 'parada mais cedo' com diferentes números de iterações para interrupção do treinamento e diferentes RNAs (21-n₁-n₂-9)¹ com blocos de imagens de 64x64 pixels. (Overall Kappa coefficient, in percentage, for the early stop training method with different numbers of epochs to stop the training and different ANNs (21-n₁-n₂-9)¹ using image blocks of 64x64 pixels)

Iterações	n1-n2			
	14-14	16-16	18-18	20-20
5	63,6 B a	60,4 B a	60,1 B a	62,3 B a
100	73,8 A a	74,8 A a	72,4 A a	74,4 A a
200	73,8 A a	73,3 A a	73,2 A a	73,4 A a
400	74,6 A a	72,9 A a	74,9 A a	76,0 A a
600	74,4 A a	75,1 A a	75,0 A a	75,3 A a
800	73,2 A a	75,1 A a	75,4 A a	75,2 A a

¹ = número de neurônios nas camadas de entrada, intermediárias e saída, respectivamente. Coeficientes Kappa seguidos de mesma letra maiúscula na vertical ou minúscula na horizontal, não diferem entre si pelo teste Z, ao nível de 5 % de probabilidade.

Tabela 8. Coeficiente Kappa global², em porcentagem, para o método de treinamento 'parada mais cedo' das diferentes RNAs (21-n₁-n₂-9)¹, para blocos de imagens de 32x32 pixels. (Overall Kappa Coefficient, in percentage, for the early stop method training for different ANNs (21-n₁-n₂-9)¹ using images blocks of 32x32 pixels)

n ₁	n ₂						
	26	24	22	20	18	16	14
26	60,2	61,6	59,4	60,0	59,4	60,1	59,7
24		59,9	57,9	59,3	61,6	57,3	59,7
22			60,1	59,4	59,6	60,0	57,8
20				58,6	60,4	58,8	58,3
18					58,4	60,8	58,2
16						58,3	56,5
14							58,2

¹ = número de neurônios nas camadas de entrada, intermediárias e saída, respectivamente.

² = comparações múltiplas de coeficientes Kappa pelo teste Z, não diferiram entre si, ao nível de 5 %.

Tabela 9. Coeficiente Kappa global, em porcentagem, para o método 'parada mais cedo' com diferentes números de iterações para interrupção do treinamento e diferentes RNAs (21-n₁-n₂-9)¹ com blocos de imagens de 32x32 pixels. (Overall Kappa coefficient, in percentage, for the early stop training method with different numbers of epochs to stop the training and different ANNs (21-n₁-n₂-9)¹ using image blocks of 32x32 pixels)

Iterações	n1- n2			
	14-14	16-16	18-18	20-20
5	58,2 B a	58,3 B a	58,4 B a	58,6 B a
100	62,9 A B a	64,2 A a	64,4 A a	62,2 A B a
200	63,8 A B a	64,8 A a	65,7 A a	64,3 A B a
400	63,6 A B a	64,9 A a	65,2 A a	64,7 A a
600	65,0 A a	65,8 A a	64,9 A a	64,5 A a
800	65,1 A a	65,8 A a	64,9 A a	65,7 A a

¹ = número de neurônios nas camadas de entrada, intermediárias e saída, respectivamente.

Coefficientes Kappa seguidos de mesma letra maiúscula na vertical ou minúscula na horizontal, não diferem entre si pelo teste Z, ao nível de 5 % de probabilidade.

Na Tabela 10, comparando a variação no número de iterações pelo método de treinamento 'deixando um de fora', não foram obtidas diferenças significativas do coeficiente Kappa. Ou seja, para os números de iterações comparadas, não houve nem 'memorização' da amostra com 8000 iterações, nem falta de ajuste da RNA com apenas 500 iterações para este tamanho de bloco.

Tabela 10. Coeficiente Kappa global, em porcentagem, segundo treinamento pelo método 'deixando um de fora' com diferentes números de iterações, da RNA (21-14-14-9)¹ e blocos de imagens de 32x32 pixels. (Overall Kappa coefficient, in percentage, trained by leave-one-out method with different epoch numbers, of ANNs (21-14-14-9)¹ and images blocks of 32x32 pixels)

Iterações	Kappa global ²
500	64,6
1000	66,2
2000	68,8
5000	69,3
8000	66,1

¹ = número de neurônios nas camadas de entrada, intermediárias e saída, respectivamente.

² = comparações múltiplas de coeficientes Kappa pelo teste Z, não diferiram entre si, ao nível de 5 %.

Na Tabela 11 são comparados os resultados do coeficiente Kappa nos dois tamanhos de blocos e os métodos de treinamento estudados.

Comparando o coeficiente Kappa global dentro de cada bloco não apresentaram diferenças significativas entre os métodos de treinamento. Entretanto, os resultados do Kappa por classe no método de treinamento 'deixando um de fora' tenderam a resultados superiores em algumas classes de defeitos em relação ao método de 'parada mais cedo'. Isto indica que, em tais classes de defeito, o número de observações não foi suficientemente representativo para o ajuste da rede por meio deste método.

O método 'deixando um de fora', para blocos de 64x64 pixels, apresentou melhor resultado que os métodos de treinamento realizados para os blocos de 32x32 pixels. Porém, o método 'deixando um de fora' para os blocos de 32x32 pixels não diferiu do método 'parada mais cedo' para os blocos de 64x64 pixels.

Apesar do melhor resultado para bloco de 64x64 pixels, não se deve descartar a utilização de blocos menores em um classificador, pois, estes apresentam uma melhor resolução espacial na imagem classificada. Conseqüentemente, os formatos dos defeitos serão mais bem representados e quantificados. Portanto, o tamanho de bloco 32x32 pixels deve ser, também, utilizado na identificação de defeitos de madeira.

Tabela 11. Coeficiente Kappa por classe e global para dois tamanhos de blocos de imagem e dois métodos de treinamento. (Class and overall Kappa coefficients for two images block sizes and two training methods)

Classes	1/6/9/10	2	3	4	5	7/8	11	12	ml	Kappa global
Blocos 64x64										
Parada mais cedo	92,7	0,0	35,5	26,7	65,0	83,3	0,0	12,1	96,1	73,2 ab
Deixando um de fora	95,2	44,0	48,3	58,5	77,0	78,3	0,0	5,5	91,0	77,8 a
Blocos 32x32										
Parada mais cedo	91,5	-0,2	42,3	10,9	49,8	54,4	0,0	-0,2	96,1	65,1 c
Deixando um de fora	90,5	54,9	48,1	40,7	56,8	53,1	0,0	28,8	88,1	69,3 bc

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.

Coefficientes Kappa global seguidos de mesma letra, não diferem entre si pelo teste Z, ao nível de 5 % de probabilidade.

Nas Tabelas 12 e 13 são apresentadas as matrizes de erro para os melhores resultados, para blocos de 64x64 e 32x32 pixels, respectivamente. Os maiores erros ocorreram nas classes de defeitos com menor número de observações na amostra. Como são realmente menos freqüentes nas madeiras, esses defeitos teriam um peso menor no desempenho final de um sistema de classificação automática de defeitos. Os defeitos furo de inseto e podridão apresentaram os piores resultados, por terem sido incluídos na classe de madeira limpa. Isto poderia classificar uma peça de quinta classe

como de primeira (ABNT, 2002). Os defeitos fendilhado e racha também tiveram altos níveis de erro, porém foram confundidos entre si. Tendo em vista que as rachas são mais freqüentes nas extremidades da peça, tal fato poderia ajudar na distinção entre eles, acrescentando ao classificador uma informação da localização do defeito. O defeito nó sadio foi confundido com madeira limpa, o que afetaria pouco na classificação final, pois este defeito afeta somente a primeira classe de qualidade da peça (ABNT, 2002) e algumas serrarias nem o consideram como defeito (ARACRUZ, 2000).

Tabela 12. Matriz de erro da rede neural com treinamento 'deixando um de fora' com 2000 iterações, blocos de imagens de 64x64 pixels. (Error matrix for neural network trained by leave-one-out method with 2000 epochs and images blocks of 64x64 pixels)

Classe	Dados de referência									Total	Erro comissão ¹
	1/6/9/10	2	3	4	5	7/8	11	12	ml		
1/6/9/10	104	2	1	0	0	3	1	2	0	113	8,0
2	0	4	0	0	0	0	0	0	0	4	0,0
3	1	0	8	0	0	0	2	5	0	16	50,0
4	0	0	2	21	2	1	0	5	8	39	46,2
5	1	0	3	2	43	5	0	2	0	56	23,2
7/8	2	1	1	0	3	51	0	0	2	60	15,0
11	0	0	0	0	0	0	0	0	0	0	0,0
12	0	0	1	0	1	1	0	1	0	4	75,0
ml	0	2	0	11	5	2	2	1	177	200	11,5
Total	108	9	16	34	54	63	5	16	187	Erro global 16,9 %	
Erro omissão	3,7	55,6	50,0	38,2	20,4	19,0	100,0	93,8	5,3	Exatidão global 83,1 %	

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.

¹ = valores de erro e exatidão em percentagem.

Tabela 13. Matriz de erro da rede neural com treinamento 'deixando um de fora' com 2000 iterações, blocos de imagens de 32x32 pixels. (Error matrix for neural network trained by leave-one-out method with 5000 epochs and images blocks of 32x32 pixels)

Classe	Dados de referência									Total	Erro comissão ¹
	1/6/9/10	2	3	4	5	7/8	11	12	ml		
1/6/9/10	100	3	0	0	1	4	0	1	0	109	8,3
2	1	5	0	0	0	0	0	0	1	7	28,6
3	0	0	8	2	1	2	0	5	0	18	55,6
4	0	0	2	15	3	3	1	0	4	28	46,4
5	1	0	0	5	33	8	0	1	1	49	32,7
7/8	5	1	0	1	7	37	0	2	6	59	37,3
11	0	0	0	0	0	0	0	0	0	0	0,0
12	0	0	6	2	1	1	1	5	1	17	70,6
ml	1	0	0	9	8	8	3	2	174	205	15,1
Total	108	9	16	34	54	63	5	16	187	Erro global=23,4 %	
Erro omissão	7,4	44,4	50,0	55,9	38,9	41,3	100,0	68,8	7,0	Exatidão global=76,6 %	

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.

¹ = valores de erro e exatidão em percentagem.

Para confirmar se as características de percentis não foram eficientes na identificação dos defeitos que apresentaram altos níveis de erro, deve-se coletar um maior número de observações. No entanto, a exatidão dos classificadores de 83,1 e 76,6%, respectivamente para os blocos de 64x64 e 32x32 pixels, foi considerada satisfatória para que fossem utilizados na identificação de defeitos de madeira. Os defeitos de maior frequência e importância na pontuação das classes de qualidade das peças de madeira serrada obtiveram baixos níveis de erro, comparativamente à classificação humana obtida no trabalho de Huber *et al.* (1985). Estes autores avaliaram a performance de seis classificadores em três indústrias, nos quais a exatidão na discriminação de tipos de defeitos foi de 65%, valor inferior ao obtido pelo classificador de RNAs.

CONCLUSÕES

A arquitetura das RNAs escolhida apresentou 14 neurônios nas duas camadas escondidas.

Os métodos de treinamento comparados em cada tamanho de bloco, não apresentaram diferenças significativas quanto ao coeficiente Kappa. Porém, existiu uma tendência de melhor coeficiente Kappa nas classes de menor frequência, quando se utilizou o método 'deixando um de fora'.

Apesar do melhor resultado do coeficiente Kappa para bloco de 64x64 pixels, não se deve descartar a utilização de blocos menores em um classificador, pois, estes apresentam uma melhor resolução espacial na imagem classificada.

Classificadores por redes neurais artificiais, utilizando-se características de percentis das bandas vermelho, verde e azul foram considerados satisfatórios na identificação dos defeitos de madeira serrada de eucalipto, obtendo exatidão global de 83,1 e 76,6% para os blocos de 64x64 e 32x32 pixels, respectivamente.

AGRADECIMENTOS

Este trabalho teve apoio financeiro da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

REFERÊNCIAS BIBLIOGRÁFICAS

ABNT - ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 14806: Madeira serrada de eucalipto – Requisitos.** Rio de Janeiro, 2002. 11p.

ARACRUZ. **Descrição do produto.** Nova Viçosa: Aracruz Produtos de Madeira S.A., 2000. 9p.

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

GONZALEZ, R.C.; WOODS, R.E. **Processamento de imagens digitais.** São Paulo: Editora Edgard Blücher Ltda, 1992. 509p.

HAYKIN, S. **Neural networks: a comprehensive foundation.** 2.ed. New Jersey: Prentice Hall, 1999. 842p.

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

HUDSON, W.D.; RAMM, C.W. Correct formulation of the Kappa coefficient of agreement. **Photogrammetric Engineering and Remote Sensing**, Bethesda, v.53, n.4, p.421-422, 1987.

KAUPPINEN, H. **Development of a color machine vision method for wood surface inspection.** 1999. 138p. (Dissertation) - Department of Electrical Engineering and Infotech Oulu, University of Oulu, Oulu, 1999. Disponível em: http://herkules.oulu.fi/issn_03553213/

MATEUS, G.R.; LUNA, H.P.L. **Programação não linear.** Belo Horizonte: Editora Gráfica Formato Ltda, 1986. 289p.

MATLAB. **User's guide.** Natick: The Math Works Inc., 2000.

PACKIANATHER, M.S.; DRAKE, P.R. Neural networks for classifying images of wood veneer: part 2. **International Journal of Advanced Manufacturing Technology**, Southampton, v.16, n.6, p.424-433, 2000.

PINTO, F.A.C; REID, J.F; ZHANG, Q.; NOGUCHI, N. Guidance parameter determination using artificial neural network classifier. In: ASAE MEETING PRESENTATION, 1999, Toronto. **Proceedings.** Toronto: University UILLU, 1999. Paper 993004, 14p.

PRECHELT, L. Automatic early stopping using cross validation: quantifying the criteria. **Neural networks**, Ithaca, n.11, p.761-767, 1998.

REGAZZI, A.J. **Análise multivariada: notas de aula INF 766**. Viçosa: Departamento de Informática, Universidade Federal de Viçosa, 2000. v.2

ROSENFELD, G.H.; FITZPATRICK-LINS, K. A coefficient of agreement as a measure of thematic classification accuracy. **Photogrammetric Engineering and Remote Sensing**, Bethesda, v.52, n.2, p.223-227, 1986.

SARIGUL, E.; ABBOTT, A.L.; SCHMOLDT, D.L. Rule-driven defect detection in CT images of hardwood logs. **Computers and electronics in agriculture**, Amsterdam, n.19, p.101-119, 2003.

SAS INSTITUTE. **SAS Online Doc**. Version 8. Cary: SAS Institute Inc., 1999.

Recebido em 01/02/2005

Aceito para publicação em 23/02/2006