

CLASSIFICADOR ADAPTATIVO PARA O RECONHECIMENTO DE ALVOS EM IMAGENS CCD/CBERS

An adaptative classifier for the recognition of targets in CCD/CBERS images

Viviane Todt^{1,2}
Cléber Rubert¹
José Demísio Simões da Silva¹
Antonio Roberto Formaggio¹
Yosio Edemir Shimabukuro¹

¹**INPE - Instituto Nacional de Pesquisas Espaciais**
PGSER - Programa de Pós-Graduação em Sensoriamento Remoto
CAP - Pós-Graduação em Computação Aplicada
Av. dos Astronautas, 1758 - Jardim da Granja - São José dos Campos - SP - 12227 010 - Brasil
{viviane, formag, yosio}@ltd.inpe.br, cleber@dpi.inpe.br, demisio@lac.inpe.br

²**UNISINOS - Universidade do Vale do Rio dos Sinos**
Centro de Ciências Exatas e Tecnológicas
Av. Unisinos, 950 - Cristo Rei - São Leopoldo - RS - 93022 000 - Brasil
vivianed@unisinos.br

RESUMO

Este trabalho apresenta um classificador neural integrado que visa aumentar a acurácia no reconhecimento de diferentes feições em imagens do sensor CCD/CBERS. Entre essas feições encontram-se capões nativos e áreas de reflorestamento de *Araucaria angustifolia* localizados dentro e aos arredores da Floresta Nacional de São Francisco de Paula. Essa FLONA é considerada a unidade de conservação mais antiga do estado do Rio Grande do Sul, Brasil. O classificador neural proposto é dito integrado pelo fato de ser constituído por três modelos de redes neurais agrupados através de duas abordagens distintas de integração: abordagem 2/3 e abordagem pelo critério da credibilidade. Os classificadores neurais utilizados foram: Perceptron de Múltiplas Camadas com Retropropagação de Erros, Quantização Vetorial por Aprendizagem e Rede de Função de Base Radial. Os experimentos desenvolvidos mostram que o modelo neural integrado, pelo critério de credibilidade, contribui para aumentar a acurácia na identificação de feições, mostrando-se promissor para outras aplicações, tais como o monitoramento em tempo real de alvos da superfície terrestre.

Palavras chaves: Redes Neurais Artificiais, sensor CCD, satélite CBERS, *Araucaria angustifolia* .

ABSTRACT

This work presents an integrated neural classifier aiming to increase the accuracy in the recognition of different features inside CCD/CBERS images. Among these features there are native capons and areas of reforestation of *Araucaria angustifolia* located in the interior and in the proximities of the Sao Francisco de Paula National Forest. This forest is considered the older conservation unit from Rio Grande do Sul state, Brazil. The considered neural classifiers are said integrated because they are constituted of three models of neural nets grouped in two distinct approaches of integration: a) the two-third approach, and b) the credibility criterion approach. The used neural classifiers were: Multi-layer Perceptron, Learning Vector Quantization, and Radial Basis Function. The developed experiments showed that the integrated neural model using the credibility criterion approach contributes for increasing the accuracy in the identification of features, revealing promising for other applications, such as the monitoring in real time of the terrestrial surface.

Keywords: Artificial Neural Nets, CCD sensor, CBERS satellite, *Araucaria angustifolia*.

1. INTRODUÇÃO

Em termos gerais, o reconhecimento de feições em imagens digitais segue uma seqüência de etapas que inicia com a aplicação de técnicas de pré-processamento e aquisição de dados *in situ* e termina com o emprego de uma técnica de classificação propriamente dita. Na maioria das vezes, uma imagem é pré-processada através da aplicação de técnicas de correção radiométrica e geométrica, registro, aumento de contraste, aplicação de filtros espaciais ou no domínio de Fourier, aplicação do modelo linear de mistura espectral, aplicação de máscaras e segmentação. Após, parte-se para a etapa de aquisição de dados *in situ* e a criação de uma base de conhecimentos/dados que agrega a experiência de um especialista na área de estudo e que serve de referência para o processo de classificação. Por fim, faz-se a classificação digital propriamente dita através do emprego de classificadores que particionam o espaço de atributos em regiões espectralmente homogêneas.

Tradicionalmente, a classificação digital de imagens multiespectrais é realizada através de classificadores que se baseiam no Teorema de Bayes. Os classificadores Bayesianos são ditos ótimos (no sentido de que minimizam a probabilidade de erro) quando as hipóteses sobre as distribuições de probabilidade são corretas, para as diversas classes (alvos/feições) existentes na imagem. Assim, uma classificação insatisfatória pode ser obtida, se as probabilidades de densidade das feições de interesse são diferentes daquelas assumidas pelo modelo. Usualmente, utiliza-se o modelo de Máxima Verossimilhança Gaussiana que é um classificador Bayesiano com distribuição de probabilidade gaussiana (RICHARDS *et al.*, 1999, LEMOS *et al.*, 2005). Dessa forma, considera-se que as distribuições internas de cada classe da imagem a ser classificada possuem distribuição normal.

O método de Máxima Verossimilhança Gaussiana é caracterizado por sua robustez no que diz respeito à existência de pequenos desvios de normalidade dos dados. Porém, nem sempre os dados das imagens multiespectrais apresentam distribuição de probabilidade normal e, portanto, classificadores gaussianos não seriam a melhor técnica de classificação para esses casos. Dessa forma, as redes neurais artificiais (RNAs) surgem como uma alternativa para uma variedade de problemas de classificação.

SCHOWENGERDT (1997) refere-se a um classificador neural como sendo uma abordagem não paramétrica e iterativa, que faz uso dos atributos dos alvos de interesse extraídos da imagem de satélite para formar o conjunto de *pixels* de treinamento. Esse conjunto, por sua vez, pode ser constituído não somente por vetores multiespectrais, mas também pelo comportamento espectral de *pixels* vizinhos (textura), por vetores espectro-temporais, por dados oriundos da razão entre bandas, por características de um determinado alvo em diferentes ângulos de visada, por dados do modelo numérico do terreno ou por outros atributos que de uma forma ou de outra caracterizem os alvos de interesse.

Como a rede neural é totalmente independente do sensor, pode-se também fornecer como entrada para a rede os dados obtidos por mais de um sensor (após a harmonização das resoluções espaciais dos dados), para melhor reconhecer os alvos de interesse. Além disso, os dados podem ser oriundos tanto de sensores multiespectrais (AVHRR, MSS, TM, SPOT), quanto de radar (SAR) ou hiperespectrais (AVIRIS, ASA). Outra possibilidade é agregar dados obtidos através de fotografias aéreas.

Entre os diversos modelos de redes neurais existentes na literatura (HAYKIN, 2001), o Perceptron de Múltiplas Camadas é o mais empregado em Sensoriamento Remoto. Todavia, MATHER (1999) ressalta que esse não é o único modelo neural que tem sido utilizado nessa área. Modelos neurais não supervisionados, ou seja, que não fazem uso de um conjunto de treinamento, também têm sido estudados. Entre esses modelos, o autor cita o uso de Mapas Auto-Organizáveis de Kohonen para a classificação da cobertura da terra e a rede ART para a classificação de vegetação.

Uma outra ramificação do emprego de redes neurais na área de sensoriamento remoto diz respeito ao uso integrado de redes neurais, de outros métodos tradicionais e/ou de outras técnicas baseadas em inteligência artificial, tais como os sistemas especialistas. LIU *et al.* (2002) propõem uma abordagem totalmente integrada visando melhorar a acurácia na classificação. Nesse trabalho, os autores avaliam o desempenho de dois classificadores integrados: CSB (*Consensus Builder*) e ESNNC (*Expert System-Neural Network Classifier*). O primeiro classificador integrado denominado CSB é formado por um classificador Máxima Verossimilhança, um Sistema Especialista e um Perceptron de Múltiplas Camadas com algoritmo de retropropagação de erros. Ou seja, os autores utilizam duas técnicas de Inteligência Artificial agregadas e combinadas com o classificador Máxima Verossimilhança que, dentre os métodos tradicionais, é o que geralmente apresenta melhores resultados na classificação *pixel a pixel* de imagens multiespectrais. O segundo classificador integrado desenvolvido e avaliado pelos autores, o ESNNC, é constituído somente por um Sistema Especialista e uma rede neural (Perceptron de Múltiplas Camadas com retropropagação de erros). Para esse estudo, os autores utilizaram imagens dos satélites SPOT e LANDSAT, dentro de uma abordagem pontual (*pixel a pixel*), além de dados relativos à declividade e elevação do terreno e do tipo de solo. Esse conjunto de dados serviu como entrada tanto para a rede neural, quanto para os demais classificadores. Como resultado, os autores constataram que o classificador integrado ESNNC apresentou a maior acurácia total (80%) para a área de estudo, sendo significativamente superior ao CSB (72%) e aos três classificadores MAXVER (62%), Sistema Especialista (59%) e rede neural (74%), utilizados separadamente.

Tendo como base a abordagem proposta e os resultados obtidos por LIU *et al.* (2002), o presente trabalho apresenta a metodologia desenvolvida para a

criação de um sistema neural integrado para o reconhecimento de alvos em imagens de média resolução espacial obtidas a partir de satélites de recursos naturais. Porém, nesse caso, a presente metodologia utiliza três modelos de redes neurais que são empregados de forma integrada, como se os modelos formassem uma equipe para a resolução de um problema específico. Dentro desse contexto, adotou-se a seguinte hipótese: “três cérebros devidamente treinados para a realização de uma missão específica apresentam um desempenho significativamente melhor do que se a mesma missão fosse realizada por apenas um único cérebro”. Assim, o sistema proposto nesse trabalho é formado por três “cérebros” (modelos neurais), cada qual regido por um determinado modelo de rede neural, e com a missão de identificar oito diferentes alvos em imagens CCD, obtidas pelo satélite CBERS. Salienta-se que duas abordagens de integração são propostas: uma abordagem mais simples denominada 2/3 e uma outra abordagem mais elaborada, denominada abordagem com critério de credibilidade.

2. REDES NEURAIAS ARTIFICIAIS

Uma Rede Neural, também conhecida como Rede Neuronal, Neurocomputador ou Rede Conexionista, é um conjunto de elementos processadores individuais (neurônios formais), agrupados sob as mais diversas topologias e regidos por procedimentos matemáticos de *clusterização* de vetores, otimização discreta, minimização de erros, entre outros (HAYKIN, 2001).

A inspiração para o desenvolvimento dos diversos modelos de redes neurais hoje relatados na literatura é baseada na estrutura e no funcionamento do cérebro humano e/ou do sistema nervoso central, e o interesse despertado por essa técnica deve-se, na maioria das vezes, às seguintes características apresentadas pelas redes: processamento paralelo de informações, alta velocidade de processamento, capacidade de generalização de seu conhecimento, plasticidade/adaptação ao meio e, por último, pelo fato de ser uma técnica não-paramétrica e não-linear que permite o mapeamento de dados de entrada com dados de saída associados.

As redes neurais, quando voltadas para a classificação de padrões, devem associar cada exemplo/padrão que lhe é fornecido a uma classe, aquela à qual esse padrão mais se assemelhe. Portanto, a saída da rede é a classe associada ao exemplo/padrão fornecido.

No caso de redes neurais com aprendizado supervisionado, o conjunto de classes é conhecido antes de se iniciar o processo de aprendizado. Neste estudo, o conjunto de treinamento é constituído por oito classes que ocorrem na área de estudo: 1) mata nativa com predominância de Araucária, 2) mata nativa sem predominância de Araucária, 3) *pinus*, 4) campo, 5) solo exposto, 6) estrada, 7) nuvem e 8) sombra.

Dessa forma, o classificador neural integrado aqui proposto, formado por três modelos de redes neurais, realiza o mapeamento dos dados de entrada (contadores

digitais) em uma das oito possíveis classes que ocorrem na área de estudo.

Visando proporcionar adequada fundamentação, as próximas seções apresentam as principais características dos três modelos neurais empregados na abordagem integrada e a estrutura neural utilizada para a aplicação em questão.

3. O CLASSIFICADOR ADAPTATIVO

O classificador neural integrado é constituído por três modelos neurais conhecidos como: 1) Perceptron de Múltiplas Camadas, 2) Quantização Vetorial e 3) Redes de Função de Base Radial. Esses modelos individuais foram integrados através de duas heurísticas de integração: 1) abordagem 2/3 e 2) abordagem com critério de credibilidade.

3.1 Perceptron de Múltiplas Camadas

Os *Perceptrons* de Múltiplas Camadas (*Multilayer Perceptron* – MLP) (figura 1) têm sido aplicados com sucesso na solução de diversos problemas complexos, através de seu treinamento de forma supervisionada, com um algoritmo muito conhecido denominado retropropagação do erro (*error back-propagation*) (DIVERIO *et al.*, 2003; HAYKIN, 2001; MATHER, 1999; SCHOWENGERDT, 1997; FAUSETT, 1994).

Para esse trabalho, utilizou-se um MLP constituído por três neurônios de entrada (um para cada banda do sensor CCD/CBERS-1), oito neurônios de saída (um para cada classe de interesse) e uma única camada escondida contendo 6 neurônios intermediários. Os valores utilizados para a rede neural foram: 1.0 para o parâmetro alfa, 0.2 para a taxa de aprendizagem e 150 para o número de iterações. Utilizou-se a tangente hiperbólica como função de ativação.

Nessa implementação, cada neurônio de saída da rede representa uma determinada classe. Assim, dado um padrão/exemplo, a classe a ele atribuída é aquela associada ao neurônio de saída que teve a maior ativação. Nessa abordagem, não se considerou a possibilidade da existência de uma classe dita desconhecida. Logo, após a etapa de treinamento da rede, cada *pixel* da imagem foi rotulado com uma das oito possíveis classes existentes na área de estudo. A classe desconhecida só aparece na etapa de integração dos resultados fornecidos pelos três modelos neurais e na geração da classificação final (ver seção 5).

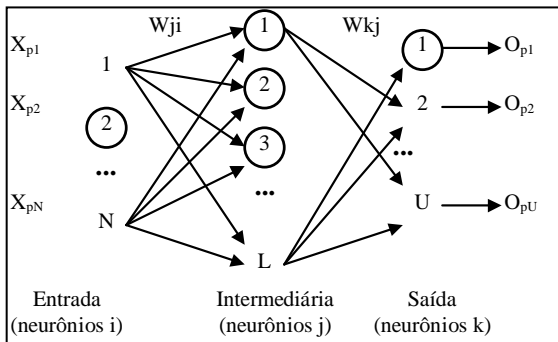


Fig. 1 – Perceptron Múltiplas Camadas.

3.2 Quantização Vetorial

As redes LVQ (*Learning Vector Quantization*) definem uma família de algoritmos de quantificação vetorial adaptativa, originalmente propostos por Kohonen (HAYKIN, 2001; FAUSETT, 1994). Os algoritmos LVQ estão relacionados com quantização vetorial e com os Mapas Auto-Organizáveis (SOM). Embora esses últimos sejam utilizados na identificação de *clusters* e no treinamento não supervisionado, as redes LVQ (figura 2) definem métodos de treinamento supervisionado. Essa característica, por sua vez, sugere a utilização desse modelo neural para a classificação e reconhecimento de padrões, a partir de um conjunto de amostras de treinamento. Ou seja, o seu objetivo é definir subespaços no espaço definido pelas amostras de entrada que melhor definam as classes pré-estabelecidas (HAYKIN, 2001).

O algoritmo utilizado nesse trabalho foi o LVQ2 (FAUSETT, 1994).

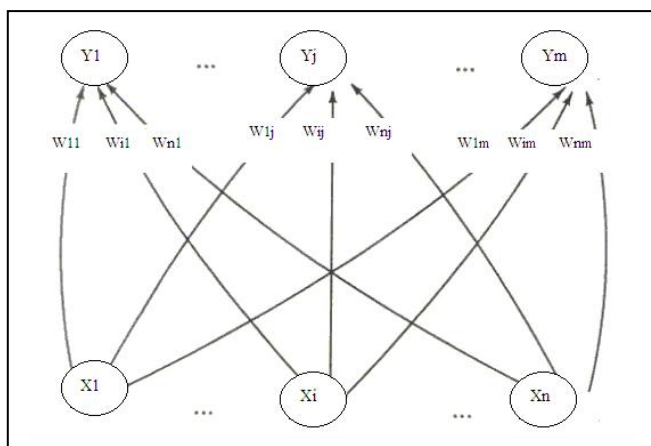


Fig. 2 – Rede LVQ. Fonte: adaptado de FAUSETT (1994).

Para a implementação desse modelo, empregou-se uma rede LVQ constituída por três neurônios de entrada X_i (um para cada banda CCD – bandas 2, 3 e 4, respectivamente, com seus valores devidamente normalizados entre -1 e 1) e oito neurônios de saída Y_j (um para cada classe pré-definida). Para o treinamento

dessa rede neural, realizou-se 500 iterações, adotando-se 0.3 para o parâmetro conhecido como coeficiente de aprendizado.

3.3 Rede de Função de Base Radial

Recentemente, as redes de função de base radial (*Radial Basis Function – RBF*, figura 3) têm tido uma significativa posição dentro do domínio das redes neurais artificiais. A principal razão para isso é a simplicidade do processo de treinamento e a eficiência computacional. A estrutura da rede RBF é do tipo múltiplas camadas, o método de treinamento é do tipo *feedforward* e o treinamento pode ser supervisionado ou híbrido no qual combina-se um método não-supervisionado. Maiores informações sobre a estrutura e o funcionamento de uma rede RBF podem ser encontradas em HAYKIN (2001), FAUSETT (1994) e DUDA *et al.* (1994).

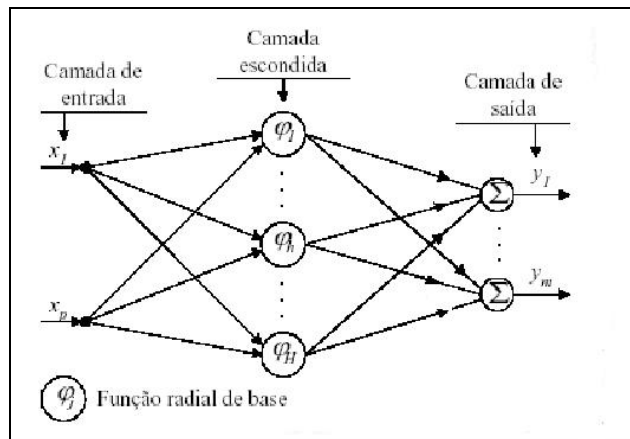


Fig. 3-Rede RBF. Fonte: adaptado de FERNANDES (1999).

Para esse trabalho, a rede utilizada foi constituída por três neurônios de entrada X_i (um para cada banda CCD – bandas 2, 3 e 4, respectivamente, com seus valores devidamente normalizados entre -1 e 1) e oito neurônios de saída Y_j (um para cada classe pré-definida). Para o treinamento, utilizou-se os seguintes valores: 15.000 para o número de iterações, 0.3 para o parâmetro conhecido como coeficiente de aprendizado e 12 para o número de neurônios da camada intermediária. Adotou-se o treinamento supervisionado, ao invés do híbrido.

3.4 Abordagens de integração

Os modelos neurais individuais (MLP, LVQ e RBF) foram integrados através do desenvolvimento de duas abordagens distintas.

A abordagem mais simples e já bastante utilizada, denominada 2/3, considera três situações possíveis: 1) as três redes concordam na classe a ser atribuída ao *pixel* em questão; 2) as três redes discordam ou 3) duas redes concordam e uma rede discorda. Para essa abordagem, caso as três redes discordem, a classe “desconhecida” é atribuída e, caso duas redes concordem

e uma rede discorde, o critério adotado é “vence a maioria”. A tabela 1 mostra um exemplo hipotético que ilustra qual classe seria atribuída a um *pixel*, em cada uma dessas situações.

TABELA 1 – ABORDAGEM 2/3.

Situação	MLP	LVQ	RBF	Classe atribuída
1	classe 1	classe 1	classe 1	classe 1
2	classe 1	classe 2	classe 3	desconhecida
3	classe 2	classe 4	classe 2	classe 2

A segunda abordagem aqui desenvolvida considera um critério de credibilidade para cada “cérebro” dependendo da classe para o qual ele está sendo solicitado a “opinar”. Nesse caso, parte-se do princípio de que se uma rede, após o seu treinamento, mostrou ser especialista na identificação de uma determinada classe, então, quando a mesma classificar um *pixel* como sendo dessa classe, sua “opinião” deverá ter um peso maior do que a “opinião” das demais redes. As três situações citadas na abordagem 2/3 são codificadas nessa abordagem, conforme mostra a tabela 2. Entretanto, na abordagem de credibilidade, as situações 2 (as três redes discordam) e 3 (duas redes concordam e uma rede discorda) são tratadas de forma diferenciada, considerando as credibilidades associadas. Para facilitar o entendimento da abordagem utilizada, vamos considerar que dado um *pixel* qualquer, cada rede vota ou “opina” em uma determinada classe. Por sua vez, o método de integração recebe os três votos e os analisa considerando a credibilidade que cada rede tem naquilo ao qual ela está “dizendo” ser a classe correta para o *pixel* em questão.

No primeiro caso, considera-se a situação das três redes concordarem sobre a classe do *pixel*. Nesse contexto, a classe comum é atribuída ao mesmo.

Quando houver divergência entre as três redes sobre a classe correta para o *pixel* (exemplo: a rede MLP vota na classe 2, a rede LVQ vota na classe 3 e a rede RBF vota na classe 4), os critérios de credibilidade precisam ser considerados para que se possa definir qual das redes tem “razão” no que está dizendo. Os critérios de credibilidade que aparecem na tabela 2 variam de 0 a 5, conforme a classe e a rede associada. Essas credibilidades são definidas como se fossem “pesos de opinião”, através de: 1) análise visual do desempenho dos classificadores individuais; 2) conhecimento do especialista na área de estudo e, 3) resultados obtidos com as tabelas de confusão e índices *kappa*. Para esse exemplo, da tabela 2, como cada rede vota em uma classe diferente e cada rede tem uma credibilidade diferente, atribui-se ao *pixel* a classe da rede RBF que possui a maior credibilidade (credibilidade = 5) naquilo em que ela está opinando (classe 4).

TABELA 2 – ABORDAGEM DE CREDIBILIDADE.

Sit	Variáveis	MLP	LVQ	RBF	classe atribuída
1	voto cred	classe 2 3	classe 3 4	classe 4 5	classe 4
2	voto cred	classe 2 3	classe 3 3	classe 4 3	desconhecida
3	voto cred <i>kappa</i>	classe 2 3 54,1	classe 3 2 28,4	classe 4 3 55,4	classe 4
4	voto cred	classe 2 2	classe 3 3	classe 4 2	classe 3
5	voto cred	classe 2 3	classe 2 4	classe 4 5	classe 4
6	voto cred	classe 2 3	classe 2 3	classe 4 3	classe 2
7	voto cred	classe 2 2	classe 2 2	classe 4 3	classe 4
8	voto cred <i>kappa</i>	classe 2 2 54,1	classe 2 3 28,4	classe 4 3 55,4	classe 4

Todas as combinações possíveis de discordância são apresentadas na tabela 2. Abaixo, ilustra-se algumas delas:

- cada rede vota em uma classe diferente e todas as redes têm a mesma credibilidade no que estão opinando. Nesse caso, atribui-se a classe como sendo “desconhecida”.
- cada rede vota em uma classe diferente, porém duas redes têm a mesma credibilidade no que estão opinando. Além disso, essa credibilidade é maior do que a credibilidade associada à rede que discorda. Nesse caso, a acurácia global obtida pelo índice *Kappa* é adotado como critério de desempate.
- cada rede vota em uma classe diferente e duas têm a mesma credibilidade no que estão opinando. Entretanto, essa credibilidade é menor do que a credibilidade associada à rede que discorda. Logo, mantém-se o critério de credibilidade como sendo o mais importante e atribui-se a classe com maior credibilidade para o *pixel*.

As próximas seções descrevem a área de estudo, o material utilizado, as técnicas de pré-processamento empregadas e apresentam maiores detalhes sobre o treinamento dos modelos neurais, a integração e a validação do sistema.

4. ÁREA DE ESTUDO

A área de estudo, cerca de 11 x 13 Km², situa-se no nordeste do Planalto RioGrandense (coordenadas UTM: 550.350;6.750.119 e 564.089;6.736.050), cerca de 139 Km da capital do estado (Porto Alegre) e inclui a Floresta Nacional de São Francisco de Paula (figura 4). Essa Floresta está situada no município de São Francisco de Paula e é considerada a unidade de preservação mais antiga do Estado do Rio Grande do Sul. Embora parte de sua área tenha sido utilizada em reflorestamento com espécies exóticas (tais como *Pinus*), a mesma se constitui num dos ambientes característicos da Floresta Ombrófila Mista do tipo Montana. O clima da região mantém índices de umidade bem distribuídos (2.162 mm³/ano) e as temperaturas médias variam entre 19°C e 22°C, no verão, e entre 3°C e 11°C, no inverno. Os solos são delgados (0,50m – 2m, em média), avermelhados e ácidos (pH 4, 9-5,2).




Fig. 4 - Composição R(4)G(3)B(2) da área de estudo. Imagem CCD/CBERS 1 processada com *Wavelets*.

5. MATERIAL E MÉTODO

O satélite CBERS 1 possui a bordo três sensores: WFI (*Wide Field Imager*), CCD (*High Resolution CCD Camera*) e IR-MSS (*Infra-red Multi-spectral Scanner*). Diversas são as características que os distinguem entre si e que torna cada sensor mais apropriado para uma determinada aplicação. O sensor WFI, em função de sua resolução espacial de 260 metros, é apropriado para estudos regionais. O sensor CCD, utilizado nesse trabalho, possui uma resolução espacial nominal de 20 metros o que permite a identificação e o mapeamento de pequenos capões nativos de Araucária na área de estudo. Por sua vez, o sensor IR-MSS, com resolução espacial nominal de 80 metros e com bandas no infravermelho próximo e termal, tem sido utilizado em mapeamentos de

desflorestamentos da Amazônia Brasileira (DIVERIO *et al.*, 2003).

O sensor CCD possui cinco bandas que cobrem os seguintes intervalos do espectro-eletromagnético: banda pancromática (0.51 – 0.73 µm), banda azul (0.45 – 0.52 73 µm), banda verde (0.52 – 0.59 µm), banda vermelha (0.63 – 0.69 µm) e banda no infravermelho próximo (0.77 – 0.89 µm). Esse sensor possui uma largura de faixa imageada correspondente a 113 Km e sua resolução temporal é de 26 dias com visada vertical e de 3 dias com visada lateral. Outras informações a respeito desse sensor e/ou dos demais sensores a bordo do satélite CBERS podem ser obtidas em INPE (2006).

No que se refere aos aplicativos, utilizou-se o MATLAB (versão 6) para a implementação dos três modelos neurais e dos algoritmos de integração que, por sua vez, constituíram o sistema proposto. A técnica de *Wavelets*, como será citada a seguir, também foi implementada dentro desse ambiente. Os resultados das classificações obtidos foram analisados visualmente através do programa MULTISPEC (versão 2.5), de domínio público e desenvolvido pela Universidade de Purdue (www.purdue.edu). Por último, alguns pré-processamentos das imagens foram realizados através do programa SPRING (www.dpi.inpe.br/spring).

Em termos gerais, a metodologia empregada nesse trabalho pode ser descrita através dos seguintes passos: pré-processamento das imagens originais, coleta de amostras de treinamento e de teste, treinamento das redes neurais, geração do mapa temático final e análises quantitativas dos resultados obtidos (figura 5). As próximas seções descrevem, em detalhes, cada uma dessas etapas.

5.1 Pré-Processamento

A etapa de pré-processamento constituiu-se da eliminação de ruídos e do realce de bordas nas imagens originais (bandas 2, 3 e 4), através de uma técnica conhecida por *Wavelets* e descrita em JUNG *et al.* (2001).

Em seguida, as imagens pré-processadas pela transformada *Wavelets* foram geo-referenciadas através do emprego de um polinômio de primeiro grau e do interpolador Vizinho mais Próximo. Nessa fase, 12 pontos de controle foram identificados na imagem de satélite através de análises visuais sobre a composição colorida R(4), G(3), B(2), sobre as bandas individuais e através da carta DSG (Diretoria de Serviço Geográfico) do município de Tainhas. O erro obtido com os pontos de controle foi inferior a um *pixel*.

5.2 Aquisição de Amostras

Um total de 162 pontos/classe, dentro de uma abordagem *pixel-a-pixel*, foi coletado aleatoriamente sobre a composição colorida R(4)G(3)B(2) constituída pelas imagens pré-processadas por *Wavelets*. Desses, 54 pontos/classe, ou seja, um terço dos pontos coletados foi utilizado para o treinamento das redes neurais e 2/3 (108

pontos/classe) foram usados para a validação dos resultados obtidos.

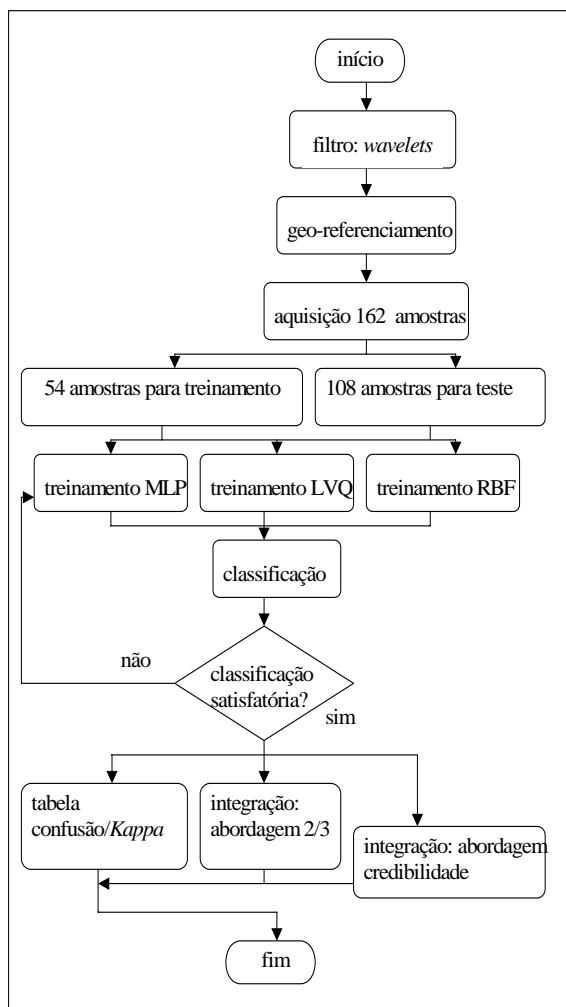


Fig. 5 - Metodologia empregada.

5.3 Treinamento das redes neurais

Cada modelo neural ou “cérebro” foi treinado para a identificação dos oito alvos de interesse citados anteriormente. Para tanto, a etapa de treinamento fez uso dos 54 pontos/classe fornecidos como estímulos de entrada para as redes de forma intercalada (amostra classe 1, classe 2, classe 3... classe 8, classe 1, classe 2, etc.) .

5.4 Geração dos mapas temáticos

Vários testes foram realizados com cada modelo neural e seus resultados foram analisados visualmente a fim de verificar consistência com a verdade terrestre e com observações *in situ*. Em seguida, os três mapas temáticos obtidos foram analisados individualmente tanto visualmente, quanto quantitativamente (através de Tabelas de Confusão e índice *Kappa*) e, se não fossem satisfatórios, todo o processo era novamente repetido (treinamento-classificação-validação).

5.5 Integração

Após a obtenção dos três melhores mapas temáticos preliminares (cada qual oriundo de uma determinada rede neural), um procedimento de integração foi executado para gerar um mapa final a partir dos mesmos. O objetivo principal aqui era manter no mapa temático final o melhor resultado obtido com cada rede neural individual. As duas abordagens de integração foram testadas: abordagem 2/3 e abordagem com critério de credibilidade.

A tabela 3 apresenta as credibilidades por classe adotadas para a área de estudo em questão. Pela tabela 3, observa-se que a rede MLP mostrou ser especialista em identificar *Pinus* e tem vantagem sobre as outras duas redes, visto que as demais nem sequer incluíram essa classe em seus mapas temáticos (credibilidades iguais a zero). Por sua vez, quando essa rede opinar sobre a classe sombra não deverá ser considerada, pois sua credibilidade para essa classe é igual a zero.

Já a rede LVQ, após o seu treinamento, se tornou especialista em identificar mata nativa sem predominância de Araucária. Assim, entre as três redes, ela é a que melhor identifica esse alvo e, quando opinar que um determinado *pixel* corresponde a essa classe, sua “opinião” deverá ser cuidadosamente considerada.

A rede RBF, por sua vez, como não teve um treinamento muito satisfatório, terá condições de opinar somente sobre dois alvos: mata nativa com predominância de Araucária e sombra, na qual é especialista, se comparada com as outras duas redes.

TABELA 3 – CREDIBILIDADES ADOTADAS.

	Arauc	Nativa	<i>Pinus</i>	Campo	Solo	Estrada	Nuvem	Sombra
MLP	1	0	5	2	3	3	3	0
LVQ	3	5	0	3	1	0	0	0
RBF	2	0	0	0	0	0	0	3

5.6 Validação do sistema

Os resultados obtidos com cada mapa temático individual e com os mapas finais gerados pelas duas abordagens de integração foram validados através da geração de tabelas de confusão e da aplicação da técnica de análise *Kappa* (estatística KHAT, variância e estatística Z), a partir das amostras de teste, conforme descrito em CONGALTON *et al.* (1998).

A classificação da área de estudo pelo Método tradicional de Máxima Verossimilhança Gaussiana, através do programa SPRING, também foi executada para servir de parâmetro de comparação. Nesse caso, adotou-se o mesmo conjunto de amostras de teste e de treinamento utilizado para as redes neurais.

6. RESULTADOS

A tabela 4 apresenta as matrizes de confusão dos três classificadores neurais individuais (MLP, LVQ2 e RBF), do classificador de Máxima Verossimilhança Gaussiana e dos dois classificadores neurais integrados (abordagem 2/3 e abordagem com critério de credibilidade).

O classificador integrado baseado no critério de credibilidade produziu valores superiores de exatidão total (80%), exatidão média do produtor (71%) e exatidão média do usuário (75%) se comparado aos valores obtidos pelos classificadores individuais, pelo método tradicional e pelo classificador integrado baseado na abordagem 2/3.

Por sua vez, obteve-se o pior desempenho com o classificador neural individual LVQ2, cuja exatidão total, exatidão média do produtor e exatidão média do usuário foi de 37%, 37% e 31%, respectivamente.

A abordagem 2/3 apresentou uma exatidão total de 62%, inferior somente à exatidão total obtida pelo método de Máxima Verossimilhança Gaussiana e pelo classificador neural integrado com critério de credibilidade. Porém, do ponto de vista do produtor da imagem classificada, a exatidão média obtida para as classes individuais foi de 55%, sendo superior somente à obtida pelo classificador LVQ2. Similarmente, do ponto de vista do usuário, esse classificador produziu uma exatidão média de 54%, superior à exatidão média do usuário obtida pelos classificadores individuais LVQ2 e RBF.

Dentre os classificadores individuais, a rede RBF produziu o maior valor de acurácia total (60%), seguida das redes MLP (59%) e LVQ2 (37%).

A tabela 5 mostra os resultados obtidos pela análise *Kappa* (estatística KHAT, variância KHAT, e estatística Z) para cada classificador testado. Em adição, a última coluna dessa tabela apresenta a qualidade do mapa temático, conforme adotado na tabela 6. Obteve-se a maior correlação positiva entre a imagem classificada e a verdade terrestre com o classificador integrado com critério de credibilidade (KHAT = 0,77), seguido do método de Máxima Verossimilhança Gaussiana (KHAT = 0,74). Entre esses dois classificadores, o modelo integrado apresentou a menor variância para a estimativa *Kappa*. Já o classificador integrado baseado na abordagem 2/3 apresentou o terceiro maior valor de concordância com a verdade terrestre (KHAT=0,57).

Apesar do classificador LVQ2 ter apresentado o pior resultado de classificação (KHAT=0,28), verifica-se, pela aplicação do teste de significância (estatística Z igual a 14,9), que o resultado da classificação é significativo ao nível de significância de 5%.

Observando-se os valores da tabela 7, que mostra os valores das estatísticas Z para a comparação par-a-par, nota-se que, para o intervalo de confiança de 95%, existe diferença significativa entre o classificador integrado com abordagem de credibilidade e todos os demais classificadores, com exceção do método de Máxima Verossimilhança Gaussiana ($Z_{\text{calc}} < 1,96$).

7. DISCUSSÃO DOS RESULTADOS

Analisando-se visualmente os resultados obtidos pelo primeiro mapa individual, resultado da rede MLP, e a tabela de confusão associada, verifica-se que a grande deficiência desse classificador neural está no reconhecimento das áreas de mata nativa sem predominância de Araucária. Por outro lado, entre os três modelos neurais individuais, esse modelo foi o que melhor identificou os trechos de estrada e as áreas com reflorestamento de *Pinus*, principalmente do ponto de vista do usuário (consumidor). Ainda para esse classificador, um elevado grau de confusão ocorreu entre a classe sombra e as áreas com reflorestamento de Araucária, como pode ser observado pelo valor de exatidão do produtor obtido para essas classes.

O segundo mapa individual, resultado da rede LVQ2, foi o único classificador individual que reconheceu as áreas com mata nativa sem predominância de Araucária. Entretanto, houve elevado grau de confusão na identificação de áreas de solo exposto, de nuvem e de sombra. Como esses alvos são espectralmente diferentes, acredita-se que essa rede neural deveria ter sido treinada mais exaustivamente com outros valores para a janela do algoritmo LVQ2.

Por sua vez, observou-se no terceiro mapa individual, resultado da rede RBF, que os resultados obtidos com esse modelo neural superestimaram as áreas de estrada. Além disso, esse classificador apresentou grandes deficiências em sua aprendizagem na identificação de mata nativa sem predominância de Araucária e *Pinus*. Assim, apesar dessa rede apresentar um valor *Kappa* superior ao da rede MLP, a mesma contribuiu no processo de integração com critério de credibilidade na identificação de áreas de solo, sombra, nuvem e Araucária.

Para o primeiro mapa final integrado, resultado da abordagem 2/3, verificou-se que houve uma superestimação da classe desconhecida e da classe Araucária, em função da abordagem mais simplista. Além disso, o resultado da integração não incluiu classes importantes como *Pinus* e mata nativa sem predominância de Araucária.

Já para o mapa temático integrado gerado pela abordagem com critério de credibilidade, pôde-se observar com bastante clareza a contribuição que cada classificador neural individual teve no mapeamento de determinadas áreas. Por exemplo: para esse mapa integrado, observou-se a interferência da rede LVQ2 na definição das áreas com mata nativa sem predominância de Araucária. Consequentemente, o mapeamento das áreas de *Pinus* e dos trechos de estrada teve influência do mapa temático individual gerado pela rede MLP, enquanto que a definição das áreas de sombra foi influenciada pelo classificador RBF. Identificou-se, ainda, que as áreas de Araucária foram mapeadas como resultantes da combinação dos três classificadores individuais, tendo interferência direta de cada um deles.

Entretanto, apesar dessa abordagem integrada ter apresentado o melhor desempenho de classificação, esse

desempenho não é significativamente superior ao obtido pelo método tradicional de Máxima Verossimilhança Gaussiana, ao nível de significância de 5% (tabela 7).

Por outro lado, seria conveniente salientar que obteve-se um valor *Kappa* pouco superior ao método tradicional, a partir de três modelos neurais individuais cujos valores de *Kappa* estão entre 20 e 60%, correspondendo aos conceitos “Razoável” e “Bom” (tabela 6). Assim, acredita-se que melhorando os treinamentos individuais de cada modelo neural e/ou com a adoção de outros critérios de credibilidade, poderia-se gerar resultados finais com uma exatidão na classificação acima de 80%. Porém, mantendo-se o mesmo conjunto de treinamento para o método de Máxima Verossimilhança e a mesma probabilidade “*a priori*” para os oito alvos, não há como melhorar a acurácia na classificação para esse método tradicional.

Outra consideração é que, uma vez que a rede neural foi treinada para identificar esses oito alvos em imagens CCD/CBERS, a mesma pode ser utilizada para a classificação de outras áreas de estudo com características similares ou com pequenas variações sazonais, simplesmente fornecendo a imagem à entrada do sistema integrado.

Outro ponto importante a ser considerado é o fato de que, através da análise qualitativa, o modelo integrado pôde discernir os alvos de interesse mesmo com todas as limitações (ruídos) inerentes às imagens, em função dos problemas de calibração da câmera CCD. Além disso, o sistema pode ser utilizado para a identificação e classificação de alvos em outras imagens de média resolução, tais como LANDSAT, SPOT, etc., sem depender de outros dados de entrada como declividade, tipo de solo, elevação e outros.

Acredita-se que o pré-processamento das imagens originais por *wavelets* facilitou o treinamento das redes. Essa técnica eliminou os ruídos existentes, salientou as bordas dos alvos e homogeneizou os mesmos. Isso pode ser visto como uma grande vantagem no momento em que a rede neural com múltiplas camadas treinada com o algoritmo *backpropagation* foi capaz de atingir o erro mínimo desejado em menos de 200 épocas.

Porém, é importante ressaltar que a maior dificuldade para a realização do processo de integração está associada justamente à definição dos critérios de credibilidade. Apesar das tabelas de confusão e dos índices *Kappa* servirem como um “guia” para a definição desses critérios, a experiência e o conhecimento do especialista na área de estudo ainda é um aspecto fundamental.

8. CONCLUSÃO

De acordo com a hipótese testada nessa pesquisa e com os objetivos previamente estabelecidos, a abordagem de integração com critério de credibilidade obteve um desempenho final considerado “muito bom”, mesmo sem a realização de testes exaustivos com os modelos neurais individuais. Conforme LANDIS & KOCH (1977 apud MOREIRA, 2005, p. 200), o conceito

“muito bom” é atribuído quando o desempenho da classificação obtida está associado a um valor *Kappa* entre 60 e 80% (tabela 6).

O classificador neural baseado nos critérios de credibilidade mostrou ser capaz de identificar e classificar satisfatoriamente os oito alvos preestabelecidos em imagens de média resolução do satélite CBERS. Porém, dado à inexistência de diferença significativa entre o método tradicional e esse classificador e em vista da complexidade de implementação da abordagem integrada, sugere-se a adoção do classificador neural com critério de credibilidade, ao invés do método tradicional, em casos específicos nos quais a exatidão do produtor e/ou do consumidor são superiores às obtidas pelo método tradicional. São eles:

- a) sob o ponto de vista do produtor, no mapeamento de: áreas nativas na área de estudo, independentemente da predominância ou não de *Araucaria angustifolia*; pastagens; áreas de solo exposto; e, áreas cobertas por sombra, seja pela existência de nuvens e/ou devido à irregularidade do terreno.
- b) sob o ponto de vista do usuário, no mapeamento de: áreas reflorestadas por *Pinus*, trechos de estrada e nuvens.

TABELA 4 – MATRIZ DE CONFUSÃO DOS CLASSIFICADORES: MLP, LVQ2, RBF, MAXVER, ABORDAGEM 2/3 E ABORDAGEM COM CRITÉRIO DE CREDIBILIDADE.

Dados de referência (colunas) e dados classificados (linhas)

MLP	Arauc	Nativa	Pinus	Campo	Solo	Estrada	Nuvem	Sombra	Usuário
Arauc	18	0	30	0	0	0	0	7	0,33
Nativa	0	0	0	0	0	0	0	0	0,00
Pinus	0	0	18	0	0	0	0	0	1,00
Campo	0	108	2	88	1	22	1	4	0,39
Solo	0	0	0	20	107	0	0	0	0,84
Estrada	0	0	0	0	0	85	9	0	0,90
Nuvem	0	0	0	0	0	1	98	0	0,99
Sombra	90	0	58	0	0	0	0	97	0,40
Produtor	0,17	0,00	0,17	0,81	0,99	0,79	0,91	0,90	-----

Exatidão Total: **59%** Exatidão do Produtor (média): **59%** Exatidão do Usuário (média): **61%**

LVQ2	Arauc	Nativa	Pinus	Campo	Solo	Estrada	Nuvem	Sombra	Usuário
Arauc	108	0	105	0	0	0	0	102	0,34
Nativa	0	108	2	0	6	0	0	2	0,92
Pinus	0	0	0	4	0	4	0	0	0,00
Campo	0	0	0	80	94	10	1	0	0,43
Solo	0	0	0	0	8	6	97	0	0,07
Estrada	0	0	0	0	0	18	7	0	0,72
Nuvem	0	0	1	0	0	0	0	4	0,00
Sombra	0	0	0	24	0	70	3	0	0,00
Produtor	1,00	1,00	0,00	0,74	0,07	0,17	0,00	0,00	-----

Exatidão Total: **37%** Exatidão do Produtor (média): **37%** Exatidão do Usuário (média): **31%**

RBF	Arauc	Nativa	Pinus	Campo	Solo	Estrada	Nuvem	Sombra	Usuário
Arauc	98	0	85	0	0	0	0	3	0,53
Nativa	0	0	4	0	0	0	0	5	0,00
Pinus	0	0	0	0	0	0	0	0	0,00
Campo	0	0	0	39	0	6	0	1	0,85
Solo	0	0	0	29	108	1	0	0	0,78
Estrada	0	108	0	40	0	83	9	6	0,34
Nuvem	0	0	0	0	0	18	99	0	0,85
Sombra	10	0	19	0	0	0	0	93	0,76
Produtor	0,91	0,00	0,00	0,36	1,00	0,77	0,92	0,86	-----

Exatidão Total: **60%** Exatidão do Produtor (média): **60%** Exatidão do Usuário (média): **51%**

MAXVER	Arauc	Nativa	Pinus	Campo	Solo	Estrada	Nuvem	Sombra	Desc	Usu
Arauc	70	0	38	0	0	0	0	0	0	0,65
Nativa	0	100	0	0	0	0	0	0	0	1,00
Pinus	15	0	56	0	0	0	0	27	0	0,57
Campo	0	0	0	50	0	0	0	0	0	1,00
Solo	0	0	0	0	96	0	0	0	0	1,00
Estrada	0	0	0	26	0	108	5	0	0	0,78
Nuvem	0	0	0	32	0	0	103	0	0	0,76
Sombra	23	0	14	0	0	0	0	81	0	0,69
Desc	0	8	0	0	12	0	0	0	0	0,00
Produtor	0,65	0,93	0,52	0,46	0,89	1,00	0,95	0,75	0,00	-----

Exatidão Total: **77%** Exatidão do Produtor (média): **68%** Exatidão do Usuário (média): **72%**

TABELA 4 (Continuação)

INTEGRAÇÃO 2/3	Arauc	Nativa	Pinus	Campo	Solo	Estrada	Nuvem	Sombra	Desc	Usu
----------------	-------	--------	-------	-------	------	---------	-------	--------	------	-----

Arauc	98	0	85	0	0	0	0	5	0	0,52
Nativa	0	0	2	0	0	0	0	0	0	0,00
Pinus	0	0	0	0	0	0	0	0	0	0,00
Campo	0	0	0	60	1	7	1	1	0	0,86
Solo	0	0	0	18	107	0	0	0	0	0,86
Estrada	0	0	0	0	0	78	8	0	0	0,91
Nuvem	0	0	0	0	0	0	96	0	0	1,00
Sombra	10	0	19	0	0	0	0	93	0	0,76
Desc	0	108	2	30	0	23	3	9	0	0,00
Produtor	0,91	0,00	0,00	0,56	0,99	0,72	0,89	0,86	0,00	-----

Exatidão Total: **62%** Exatidão do Produtor (média): **55%** Exatidão do Usuário (média): **54%**

INTEGRAÇÃO_CRE	Arauc	Nativa	Pinus	Campo	Solo	Estrada	Nuvem	Sombra	Desc	Usu
Arauc	98	0	69	0	0	0	0	12	0	0,55
Nativa	0	108	2	0	6	0	0	2	0	0,92
Pinus	0	0	18	0	0	0	0	0	0	1,00
Campo	0	0	0	88	1	22	1	1	0	0,78
Solo	0	0	0	20	101	0	0	0	0	0,83
Estrada	0	0	0	0	0	85	9	0	0	0,90
Nuvem	0	0	0	0	0	1	98	0	0	0,99
Sombra	10	0	19	0	0	0	0	93	0	0,76
Desc	0	0	0	0	0	0	0	0	0	0,00
Produtor	0,91	1,00	0,17	0,81	0,94	0,79	0,91	0,86	0,00	-----

Exatidão Total: **80%** Exatidão do Produtor (média): **71%** Exatidão do Usuário (média): **75%**

TABELA 5 – RESULTADOS DA ANÁLISE *KAPPA* PARA OS CLASSIFICADORES: MLP, LVQ2, RBF, MAXVER, ABORDAGEM 2/3 E ABORDAGEM COM CRITÉRIO DE CREDIBILIDADE.

Classificador	Estatística KHAT	Variância KHAT	Estatística Z	Qualidade do mapa temático*
MLP	0,53	0,000365	27,7	Boa
LVQ2	0,28	0,000353	14,9	Razoável
RBF	0,54	0,000362	28,4	Boa
MAXVER	0,74	0,000270	45,0	Muito Boa
Modelo Integrado: abordagem 2/3	0,57	0,000340	30,9	Boa
Modelo Integrado: abordagem com critério de credibilidade	0,77	0,000240	49,7	Muito Boa

* Qualidade da classificação associada aos valores da estatística *Kappa*, conforme LANDIS & KOCH (1977 apud MOREIRA, 2005, p. 200).

TABELA 6 – QUALIDADE DO MAPA TEMÁTICO, CONFORME ESTATÍSTICA KHAT.

Estatística KHAT	Qualidade
<0,00	Péssima
0,00 – 0,20	Ruim
0,20 – 0,40	Razoável
0,40 – 0,60	Boa
0,60 – 0,80	Muito boa
0,80 – 1,00	Excelente

FONTE: adaptado de LANDIS & KOCH(1977 apud MOREIRA, 2005, p. 200).

TABELA 7 – ESTATÍSTICA Z PARA ANÁLISE PAR-A-PAR DOS RESULTADOS DOS CLASSIFICADORES.

-----	MLP	LVQ2	RBF	MAXV	2_3	CRED
MLP	-----					
LVQ2	9,33*	-----				
RBF	0,37	9,72*	-----			
MAXV	8,33*	18,43*	7,96*	-----		
2_3	1,51	11,02*	1,13	6,88*	-----	
CRED	9,76*	20,12*	9,37*	1,33	8,30*	-----

* Diferença significativa para um intervalo de confiança de 95%

9. TRABALHOS FUTUROS

Motivados pelos resultados obtidos com essa pesquisa, os autores pretendem dar continuidade à mesma através do desenvolvimento de um mecanismo de definição de credibilidade que elimine e/ou minimize a subjetividade inserida no processo decisório, tendo como possíveis soluções: a inclusão de dados da tabela de confusão, a saída das redes neurais vista como probabilidades de classes, o emprego de técnicas *fuzzy* e/ou outra rede neural utilizada como integradora. Pretende-se, também, aplicar e validar a metodologia desenvolvida para outros sensores de média resolução e/ou para os mesmos alvos estudados, porém em outras datas de aquisição das imagens CBERS.

AGRADECIMENTOS

Ao Instituto Nacional de Pesquisas Espaciais (INPE) que, através do pesquisador Paulo Roberto Martini, disponibilizou as imagens CCD necessárias ao desenvolvimento desse trabalho. Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) que tem auxiliado financeiramente, através de bolsas de doutorado, os dois primeiros autores desse trabalho. À Universidade do Vale do Rio dos Sinos (UNISINOS) pelo suporte à realização do mesmo. À Dr^a Tânia Dutra, professora e pesquisadora da UNISINOS, pelos conhecimentos transmitidos a respeito das matas

com *Araucaria angustifolia* no estado do Rio Grande do Sul.

REFERÊNCIAS BIBLIOGRÁFICAS

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**, Lewis Publishers, 1998. 137 p.

DIVERIO, V.T.; FORMAGGIO, A.R.; SCHIMABUKURO, Y. Identificação de áreas desflorestadas na Amazônia através de uma Rede Neural Artificial utilizando imagens fração derivadas dos dados IR-MSS/CBERS. In: XI Simpósio Brasileiro de Sensoriamento Remoto, Belo Horizonte, 2003. **Anais**. p. 2697-2704, 2003.

DUDA, R.O.; HART, P.E.; STORK, D.G. **Pattern classification**, 2^a ed, John Wiley & Sons, Inc, 1994. 680 p.

FAUSETT, L. **Fundamentals of neural networks: architectures, algorithms and applications**, Prentice Hall, 1994. 460 p.

FERNANDES, M.A.C.; NETO, A.D.D.; BEZERRA, J.B. Aplicação das Redes RBF na Detecção Inteligente de Sinais Digitais. In: IV Congresso Brasileiro de Redes Neurais, São José dos Campos, 1999. **Anais**. p. 226-230, 1999.

HAYKIN, S. **Redes Neurais: princípios e prática**, 2^a ed, Makron Books, 2001. 900 p.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE. **CBERS**. Disponível em <<http://www.cbbers.inpe.br>>. Acesso: 15 abril 2006.

JUNG, C. R.; SCHARCANSKI, A. A wavelet based approach for image filtering using scale-space continuity. **Journal of Electronic Imaging**, v.10, n. 2, p. 511-520, abril. 2001.

LANDIS, J.R.; KOCK G.G. The measurement of observer agreement for categorical data. **Biometrics**, v.33, s.n., p. 159-174. 1977.

LEMOS, D. M.; HAERTEL, V. Classificador adaptativo para dados imagem em alta dimensionalidade com um conjunto pequeno de amostras de treinamento. **Revista Brasileira de Cartografia**, v.3, n. 57, p. 263-269, Dez. 2005.

LIU, X.; SKIDMORE, A.K.; OOSTEN, H.V. Integration of classification methods for improvement of land-cover map accuracy. **ISPRS Journal of Photogrammetry & Remote Sensing**, v. 56, s/n, p. 257-268, s/d. 2002.

MATHER, P.M. **Computer processing of remotely sensed images: an introduction**, 2^a ed, John Wiley & Sons Ltd, 1999. 292 p.

MOREIRA, M.A. **Fundamentos do Sensoriamento Remoto e metodologias de aplicação**, 3^a ed., Universidade Federal de Viçosa, 2005. 320 p.

RICHARDS, J.A.; JIA, X. **Remote sensing digital image analysis, an introduction**, 3^a ed, Springer, 1999. 365 p.

SCHOWENGERDT, R.A. **Remote sensing, models and methods for image processing**, 2^a ed, Academic Press, 1997. 522 p.
