

ANÁLISE DA OCUPAÇÃO DO SOLO NA AMAZÔNIA ORIENTAL ATRAVÉS DE PROCESSO CLASSIFICATÓRIO DE IMAGENS POR "FUZZY LOGIC"

Adriano Venturieri

EMBRAPA - Centro de Pesquisa Agroflorestal da Amazônia Oriental - CPATU

Trav. Dr. Enéas Pinheiro, s/n CEP: 66095-100 Belém, PA, Brasil.

E-mail: adriano@marajo.secom.ufpa.br

João Roberto dos Santos

INPE - Instituto Nacional de Pesquisas Espaciais

Av dos Astronautas, 1758. CEP: 12227-010 São José dos Campos, SP, Brasil

E-mail: jroberto@ltid.inpe.br

Ricardo José Machado

Frederico dos Santos Liporace

IBM - Centro Científico Rio, Cx. Postal 4624, Rio de Janeiro, RJ, Brasil

E-mail: rmachado@VNET.IBM.com

Abstract

Presently the deforested areas of Amazonia have been evaluated and monitored by TM-Landsat images, using both segmentation and the neural networks techniques. Success on the use of this integrated technique will allow further attempts to discriminate among different deforested areas (pasture, overgrown pasture, annual cultures). Being so, the objective of this study is to show the methodological steps of the combined use of segmentation and thematic image classification by neural systems. The area under study is the region around the Tucuruí electric power plant (SE of Pará State). The procedure for image segmentation is based on the spectral characteristics, using the region growing technique. Each segment of the area under study is labeled with thematic classes: 1. basic categories: bare soil, annual cultures, pasture, forest, regrowth (initial and advanced), burned areas and water; 2. interfering categories: shadow and clouds. During the labelling of these segments, partial decision factors (between 0 and 1) are assigned, among the boolean concepts of "false" and "true", within the procedure that defines the use of fuzzy logics. At the architecture of this classification system, the following descriptors are used: spectral, geometric, textural and contextual. The segments labelled as training areas are used to feed and feedback this neural system. Preliminary results of the initial identification of deforestation in Amazonia, presented an overall performance above 92%. It is well-known that the landuse classes in Amazonia are quite complex. Due to that, one can expect that the thematic classification by neural networks, would allow the definition of transition phenomena such as different types of pasture, different stages of regrowth, among others. The basic concept of this integrated image analysis is the use of segments of the scene, as the main information source, instead of pixels. This procedure allows a high degree of trust for the digital classification of images from Amazonia.

Resumo

Para avaliação e monitoramento das áreas deflorestadas na Amazônia têm sido desenvolvidas, atualmente, técnicas de segmentação e classificação de imagens TM/LANDSAT por redes neurais. O sucesso desta abordagem tem permitido direcionar esforços para uma estratificação das áreas deflorestadas, hoje em uso agropecuário ou em pousio. Por conseguinte, o objetivo deste trabalho é demonstrar a estratégia metodológica da combinação de técnicas de segmentação e de classificação de imagens por redes neurais, tendo como área de estudo parte da região sob influência da barragem de Tucuruí (SE do Estado do Pará). O processo de segmentação da imagem está sendo formulado com base nas características de natureza espectral, através da técnica de crescimento de regiões. Cada segmento na área de estudo está sendo rotulado em classes temáticas: solo exposto, cultura agrícola, pastagem, floresta, inicial and advanced levels of regrowth, burned, água (categorias

básicas) além de sombra e nuvem (categorias de interferência). No processo de rotulação destes segmentos está sendo atribuído à cada categoria temática, graus de pertinência parciais, entre os conceitos booleanos de falso e verdadeiro, dentro do procedimento que define a utilização de lógica nebulosa. Na arquitetura deste sistema classificador por rede neural estão sendo consideradas as informações espectral, geométrica, textural e contextual setting, cujos segmentos rotulados em áreas de teinamento servirão para treinar e realimentar tal sistema. Os resultados preliminares para as simples caracterizações de desflorestamentos têm demonstrado um desempenho global superior à 92%. Face a complexidade das classes de uso da terra na Amazônia é esperado que a arquitetura proposta de classificação por rede neural, permita o tratamento de fenômenos de transição (como áreas de pastagem, bem ou mal implantadas e/ou diferentes níveis de regrowth, por exemplo), uma vez que, não estão sendo empregados apenas pixels com seus valores espectrais no sistema classificador, mas segmentos, de onde são extraídos outros parâmetros como fonte de informação.

1. INTRODUÇÃO

Nos últimos anos a Amazônia vem sendo explorada de forma predatória causando desta forma uma série de alterações ambientais nem sempre entendidas pelo homem. O gigantismo da região aliado a métodos de monitoramento muito demorado dificultam o dimensionamento destes dados que são de fundamental importância para o planejamento de uma política de desenvolvimento. A utilização de imagens de satélite têm suprido esta aquisição de informações temporais, onde o processo de análise destes dados orbitais tem sido realizado, em sua grande maioria e para extensas áreas, por métodos convencionais de interpretação visual e em alguns casos, o procedimento analógico de extração de informações é associado ao digital.

Desta forma, monitoramento do extenso domínio da floresta tropical Amazônica é de grande relevância quando se deseja estudar os processos de transformações globais, especialmente o impacto do desflorestamento no clima e biodiversidade. A simples verificação do espaço ocupado pela atividade humana na região é ainda carente de dados confiáveis.

Há crescente necessidade de monitoramento da região Amazônica, não apenas para a definição da taxa anual de desflorestamento, mas também para o acompanhamento da dinâmica de ocupação da terra pelo homem. Para tanto é de fundamental importância discutir e apresentar um procedimento metodológico de automação do processo de extração de informação sensorial, que necessariamente envolva a utilização de técnicas de segmentação e classificação por redes neurais.

A extração de informações por método visual é baseada na experiência do foto-intérprete que, numa inspeção divide a imagem de satélite em regiões homogêneas, baseada em características espectral, textural, geométrica e de contexto. Este delineamento de regiões, uma vez rotuladas em classes temáticas, pode ser digitalizado e processado em um Geographic Information Systems (GIS). Por outro lado, nas técnicas digitais convencionais a imagem é estratificada, pelos valores espectrais, em regiões baseadas numa vizinhança pequena e no tamanho fixo de cada pixel, considerando uma determinada natureza estatística (Liporace, 1994).

O sistema classificador que objetiva o presente estudo tem como abordagem inicial a segmentação de imagem em regiões espectralmente homogêneas, através de um método derivado de algoritmo de crescimento de regiões. Cada segmento é então rotulado em classes temáticas, representando as variações de uso da terra, denominadas de **categorias básicas** e naquelas designadas por **categorias de interferências**, como nuvem e sombra. A rotulação dos segmentos nas categorias é definida por abordagem de lógica fuzzy, com graus de pertinência parciais atribuídos à cada um deles. É a partir destes segmentos que a rede neural, em um processo dito de **treinamento** pelo algoritmo **backpropagation**, extrai o conhecimento de como relacionar os descritores (espectral, geométrico, textural e contextual,) e respectivo grau de pertinência do próprio segmento às classes temáticas. A partir deste ponto a rede começa a detectar as particularidades do conjunto de treino, passando por um processo de memorização, de onde então extrai o conhecimento necessário à análise de áreas diversas.

2. ÁREA DE ESTUDO

A área de estudo está localizada na porção sudeste do Estado do Pará, de coordenadas geográficas de 3 30' a 4 30' S e de 49 30' a 50 30' W. Esta área está sob a influência da barragem de Tucuruí, tendo no sentido sul - sudoeste, uma ocupação da terra tradicional ao longo da rodovia Transamazônica e suas periféricas. A região apresenta um clima

tropical úmido, com precipitação média anual variando entre 1.300 e 3.000 mm, com período de estiagem de 1 a 3 meses. A vegetação é classificada como Floresta Ombrófila Densa, em solos profundos, de textura média à muito argilosa, permeáveis e de baixa fertilidade. A área de estudo é coberta pela órbita 224 ponto 63 do Thematic Mapper/LANDSAT-5.

3. MATERIAL E MÉTODO

Foram utilizadas as bandas TM de 1 a 5 e 7 do Landsat, cartas topográficas SA.22-Z-C-VI (Tucuruí), SA.22-Z-D-IV (Goianésia), escala 1:100.000 para realização do georeferenciamento e os softwares SITIM¹, SGI², SPRING³, desenvolvidos pelo INPE e ainda o NICE⁴ desenvolvido pela IBM. Foram também utilizados PC-486, workstation SUN-Sparc 10 and IBM/RISC 6000-530.

A Figura 1 apresenta, de forma sumarizada, os passos metodológicos para a definição dos segmentos na imagem TM/LANDSAT e o processo de treinamento da rede neural, com a geração de uma imagem temática sobre a área de estudo.

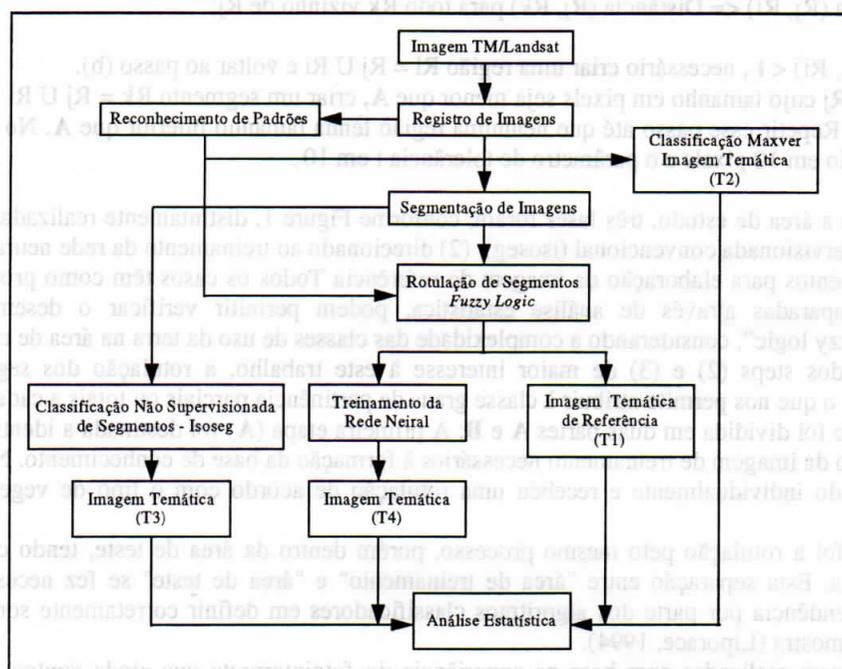


Fig 1. Diagrama do procedimento metodológico envolvendo os processos de segmentação e classificação por redes neurais.

Para caracterização da paisagem local foi realizado uma etapa de verificação de campo, justamente para entender as feições espectrais observadas nas imagens TM. Face a extensão da área de estudo e a complexidade de ocupação da terra, desde assentamentos de pequenos agricultores, exploração madeireira, pastagens extensivas e projetos de mineração, foi realizada esta verificação de campo em áreas amostrais, previamente selecionados. A área de estudo foi subdividida em uma grade, cujas amostras correspondiam às coordenadas planas (UTM) das cartas topográficas em escala 1:100.000 que, definidas por sorteio aleatório, consideravam ainda a ocorrência dos temas identificados na

¹ Sistema de Tratamento de Imagens

² Sistema Geográfico de Informações

³ Sistema de Processamento de Imagens Georeferenciadas

⁴ "Neural Image Classification Environment"

imagem. No trabalho de campo um GPS Trimble Navigation foi utilizado para localizar geograficamente pontos amostrais, os quais foram descritos, sendo alguns fotografados.

O procedimento de segmentação de imagem foi baseado no algoritmo de crescimento de regiões, que gera, a partir de um pixel (i, j) uma região que contém (i, j) e possui um valor médio de nível de cinza próximo ao de (i, j) . O grau de similaridade é determinado por um parâmetro de tolerância t , representado pela distância euclidiana entre os vetores associados a cada segmento. Tomando-se, segundo Liporace (1994), uma Distância (R_i, R_j) como medida de similaridade entre regiões R_i e R_j , que aumenta na medida que R_i e R_j se tornem mais distintas e A uma constante que determina um tamanho mínimo para cada região, a operacionalização deste algoritmo de crescimento de regiões considera:

(a) Inicialmente, cada pixel da imagem como uma região;

(b) Seja R_i e R_j duas regiões, tais que R_i seja o vizinho mais próximo de R_j . Uma região R_i é a vizinha mais próxima de R_j quando a Distância $(R_j, R_i) \leq \text{Distância}(R_j, R_k)$ para todo R_k vizinho de R_j ;

(c) Se a Distância $(R_j, R_i) < t$, necessário criar uma região $R_l = R_j \cup R_i$ e voltar ao passo (b).

(d) Para cada região R_j cujo tamanho em pixels seja menor que A , criar um segmento $R_k = R_j \cup R_i$ onde R_i é o vizinho mais próximo de R_j . Repetir esse passo até que nenhuma região tenha tamanho inferior que A . No presente trabalho o valor de A foi definido em 10 pixels e o parâmetro de tolerância t em 10.

Uma vez segmentada a área de estudo, três fases foram, conforme Figure 1, distintamente realizadas: (1) direcionado à classificação não supervisionada convencional (isoseg); (2) direcionado ao treinamento da rede neural e; (3) direcionado à rotulação dos segmentos para elaboração da imagem de referência. Todos os casos têm como produto final "imagens temáticas" que, comparadas através de análise estatística, podem permitir verificar o desempenho deste novo classificador por "fuzzy logic", considerando a complexidade das classes de uso da terra na área de estudo.

No caso específico dos steps (2) e (3) de maior interesse à este trabalho, a rotulação dos segmentos segue uma abordagem nebulosa, o que nos permite atribuir à classe graus de pertinência parciais ou totais a cada classe.

Esta fase de rotulação foi dividida em duas partes **A** e **B**: A primeira etapa (**A**) foi destinada a identificação de todos os segmentos do módulo da imagem de treinamento necessários à formação da base de conhecimento. Neste processo, cada segmento foi analisado individualmente e recebeu uma rotulação de acordo com o tipo de vegetação e/ou uso que estivesse ocorrendo.

A segunda fase (**B**) foi a rotulação pelo mesmo processo, porém dentro da área de teste, tendo como objetivo gerar imagem de referência. Esta separação entre "área de treinamento" e "área de teste" se fez necessário para que não houvesse nenhuma tendência por parte dos algoritmos classificadores em definir corretamente somente os segmentos que serviram como amostra (Liporace, 1994).

Ambas rotulações foram realizadas com base na experiência do fotointerprete que ainda contou com o apoio de 98 pontos de observações no campo (56 na área de treinamento e 42 na área de teste)

A rotulação de cada segmento consiste em um vetor $[0,1]^{10}$, com uma dimensão associada a cada classe temática. Um valor 0 (zéro) indica pertinência nula do segmento a determinada classe e um valor 1 indica pertinência total. Valores intermediários, correspondendo probabilidades de 0.75, 0.50 e 0.25 foram, pelo fotointerprete, associados aos segmentos, representando pertinências parciais. Isto como maneira de representar fenômenos de transição (como por exemplo, o estágio de regeneração da cobertura vegetal em área desflorestada) ou fenômenos de fronteira entre pixels de classes distintas, que podem dispor de características de ambas, face resolução do sensor. Após a rotulação, cada segmento é apresentado para a rede neural, através do algoritmo de backpropagation, como um conjunto de descritores que contém informação espectral, geométrica, textural e contextual de cada segmento, que por sua vez extrai conhecimentos de como relacionar tais grandezas ao grau de pertinência dos segmentos às classes temáticas existentes na imagem. Barbosa et al (1993) e Liporace (1994) descrevem com detalhes a arquitetura do sistema neural e inclusive, os medidores de desempenho da rede neural, sobretudo quando o sistema é empregado para o monitoramento com imagens Landsat do desflorestamento em áreas da Amazônia.

4. RESULTADOS

Associando a informação de campo e aquela obtida das imagens TM/LANDSAT, a legenda final ficou então constituída por 10 classes temáticas, sendo 8 de **categorias básicas** (floresta, sucessão secundária avançada, sucessão secundária inicial, pasto limpo, pasto sujo, solo agrícola, área urbana, água) e 2 de **categorias de interferência** (nuvens e sombra). Podemos observar na Tabela 1 que foram rotulados 13.946 segmentos das classes temáticas correspondendo a 446.507 pixels.

Por se tratar de uma classificação nebulosa, pode ocorrer de um mesmo segmento ser constituído de duas diferentes classes, com diferentes graus de pertinência, conforme apresentado na Tabela 2. Ocorreram ainda situações de mesmo segmento possuir duas diferentes classes com pertinência 1, chamados então de segmentos anômalos que sergem devido a erros de segmentação e também a mistura de pixels.

Como pode ser visto na Tabela 2, como forma de exemplo, uma determinada área pertencente a um segmento pode receber diferentes "rótulos", como 75% de "sucessão secundária avançada" e 25% de outras classes. Houve ainda a ocorrência de classes de interferência (nuvens e sombra) juntamente com as classes básicas. Neste caso o rótulo desses segmentos puderam totalizar mais de 100%.

Apenas como exemplo de orientação na análise destes dados (Tabela 2), pode-se verificar que dos segmentos rotulados como **Sucessão Secundária Avançada**, 35.5% do total estão relacionados com os casos com graus de pertinência 0.75 indicando haver uma mistura entre esta classe e uma das classes vizinhas e 54 % para aqueles casos de pertinência 1 indicando áreas "puras" ou seja sem mistura de outras classes. Isto ilustra nas imagens, o caso de transição no processo de crescimento da cobertura vegetal (Figura 2) e também, certa indefinição espectral nestes pixels que formam determinado conjunto de segmentos. O descritor que define determinados segmentos de **Sucessão Secundária Avançada** têm em seu espaço de atributos espectrais alguma característica de floresta, assim como alguma característica de sucessão secundária inicial (Figura 3). No processo de segmentação de imagens, o método do crescimento de regiões procura por pixels com características similares aos segmentos adjacentes, ligando-se à este segmentos se determinado critério de similaridade for satisfeito (Schoenmakers et al., 1991). Este algoritmo de agregamento é portanto baseado na análise única da média espectral do segmento contido na imagem. O limiar de similaridade pré-estabelecido, de valor $A=10$ pixels para um $t=10$, é considerado adequado, pois evita que as classes de cobertura do solo identificadas nesta área de estudo, ao possuir uma pequena variância espectral, apresente uma fragmentação excessiva.

TABELA 1 - TOTAL DE PIXELS/SEGMENTOS ROTULADOS POR CLASSE

Classe	TREINO		TESTE	
	Nº de Pixels	Nº de Segmentos	Nº de Pixels	Nº de Segmentos
Floresta	23306	656	23108	525
SSAvan	66222	1146	39228	437
SSInic	21922	407	4706	88
Plimpo	29709	498	12638	260
PSujo	75326	2147	13061	934
Solo	2763	69	2207	43
Urbana	14254	507	5550	225
Nuvem	20078	2274	9494	415
Sombra	26873	1215	30360	285
Água	12554	1691	13148	124
TOTAL	293007	10610	153500	3336

A arquitetura do sistema neural proposto e que esta em fase de treinamento pelo algoritmo de backpropagation, baseado nas classes temáticas encontradas na área de estudo, já considera um conjunto de descritores, com informações de ordem espectral, geométrica, textural e de contexto de cada segmento (Figura 4). Testes de desempenho deste sistema classificador (por cinco índices: Mean Square Error, Area Mean Square Error, Jacquard index, Hit Ratio e o Area Hit Ratio) feito em imagens da Amazônia, mas direcionada apenas a separabilidade de áreas desflorestadas daquelas de floresta e não-floresta, são discutidos por Machado et al., 1994). Neste caso, a rede neural apresentou performance superior a 92.00%, situando-se no mesmo nível de concordância existente entre foto-intérpretes distintos, quando analisados os produtos de rotulação logo após o processo de segmentação das imagens. O aumento gradual de classes de

uso da terra, hoje inseridas na rede neural, é um processo mais trabalhoso, visto que cada uma delas deve ser analisada individualmente e o treinamento da rede exige tempo para os devidos ajustes que o algoritmo de backpropagation necessita.

TABELA 2 - ROTULAÇÃO DE SEGMENTOS DA CLASSE “SUCESSÃO SECUNDÁRIA AVANÇADA” NA IMAGEM DE TREINAMENTO

Classe*	F	V	I	L	U	G	R	N	S	A	Nº de Pixel	Nº de Segmentos
	0	3	0	0	0	0	1	0	0	0	18	1
	0	3	0	0	0	1	0	0	0	0	26	1
	0	3	0	0	1	0	0	0	0	0	17	1
	0	3	0	1	0	0	0	0	0	0	50	1
	0	3	1	0	0	0	0	0	0	0	24212	352
	0	3	1	0	0	0	0	0	0	1	185	4
	0	3	1	0	0	0	0	0	0	2	20	1
	0	3	1	0	0	0	0	0	1	0	1370	28
	0	3	1	0	0	0	0	1	0	0	894	26
SSAvançada	0	4	0	0	0	0	0	0	0	0	24117	624
	0	4	0	0	0	0	0	0	0	1	1272	11
	0	4	0	0	0	0	0	0	0	2	16	1
	0	4	0	0	0	0	0	0	1	0	743	17
	0	4	0	0	0	0	0	0	2	0	208	5
	0	4	0	0	0	0	0	1	0	0	269	11
	0	4	0	0	0	0	0	2	0	0	19	1
	1	3	0	0	0	0	0	0	0	0	4649	55
	1	3	0	0	0	0	0	0	1	0	15	1
	1	3	0	0	0	0	0	0	2	0	21	1
	1	3	0	0	0	0	0	1	0	0	69	3
	1	3	0	0	0	0	0	2	0	0	32	1
											66222	1146

* F-Floresta; V-Sucessão Secundária Avançada; I-Sucessão Secundária Inicial; L-Pasto Limpo; U-Pasto Sujo; G-Solo Agrícola; R-Área Urbana; N-Nuvem; S-Sombra; A-Água

O desempenho da rede neural relacionada a sensibilidade e especificidade, medidas estas que, de maneira preliminar, podem indicar, segundo Liporace (1994) também a capacidade do classificador em detectar (sensibilidade) e de rejeitar (especificidade) determinado alvo é apresentado na Tabela 3 Contudo, a utilização na rede neural dos descritores de textura, baseados em entropia e correlação, dos descritores de vizinhança que estão associados às informações de contexto no qual o segmento está inserido, e dos descritores geométricos como a compacidade, a conexidade, contribuem significativamente para a classificação da imagem, mesmo ocorrendo um processo de aglutinação que procura restaurar regiões excessivamente fragmentadas no decorrer da fase de segmentação. A priori, é constatada, uma fidelidade na distribuição espacial das classes de uso da terra identificadas nas diversas bandas do sensor temático, superior aos processos de classificação convencionais, razão dos descritores trabalhados que, de certa forma permitem expressar as nuances fisionômicas-estruturais das classes de cobertura do solo na região.

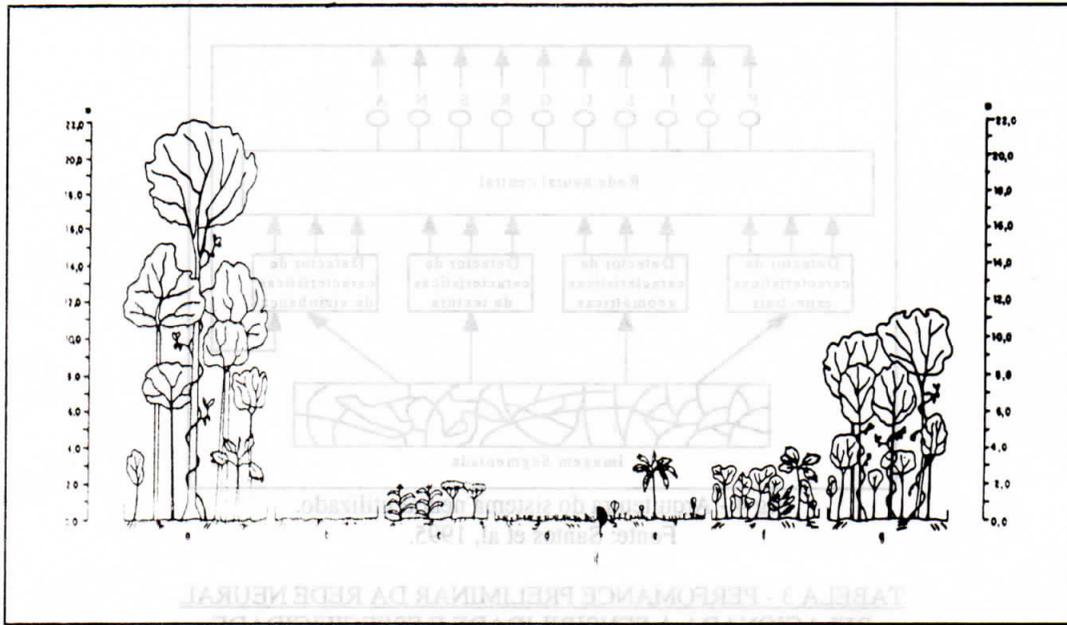


Fig 2 - Esquema representativo da transição da vegetação e uso da terra na região de estudo

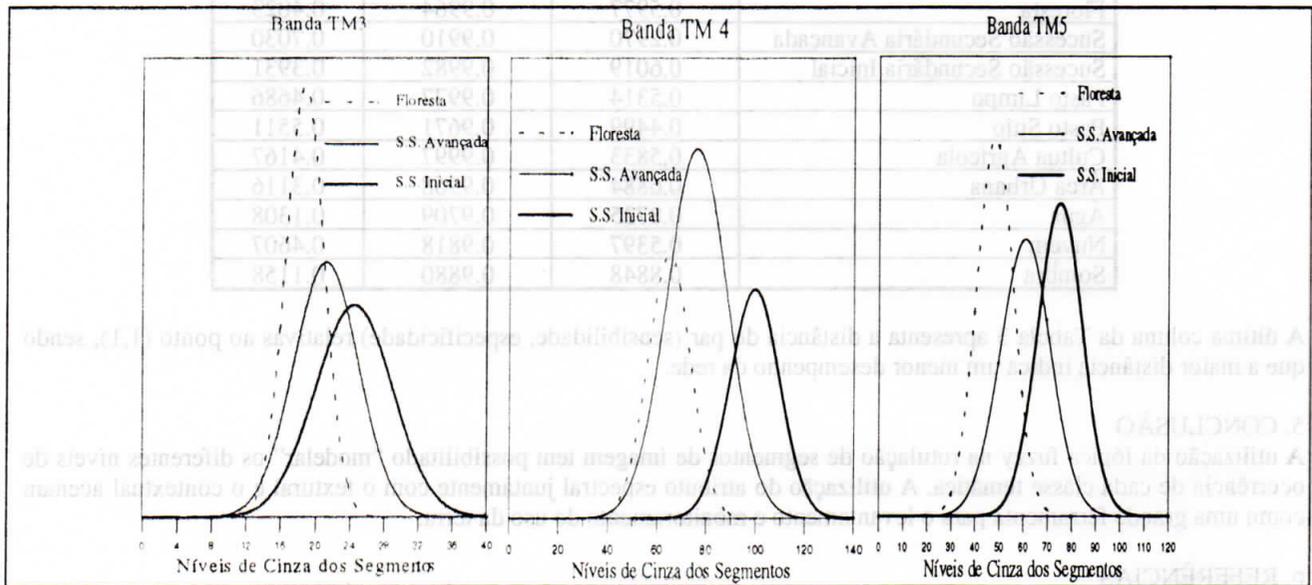


Figura 3 - Nível médio de cinza das classes de vegetação

Fonte: Santos et al, 1995.

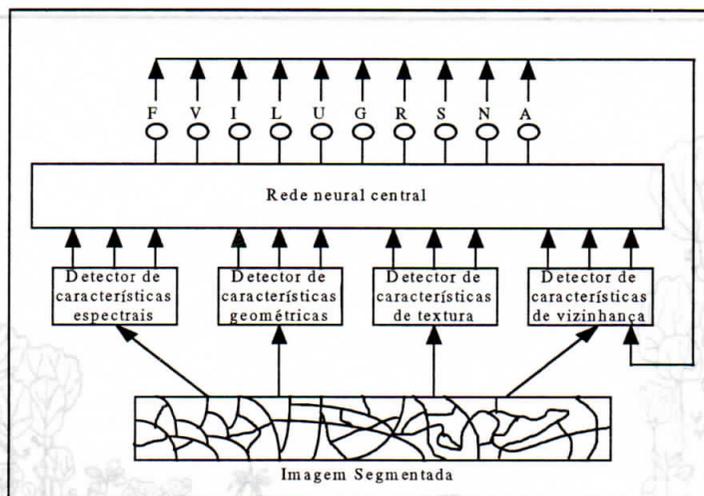


Fig 4 - Arquitetura do sistema neural utilizado.
Fonte: Santos et al, 1995.

**TABELA 3 - PERFORMANCE PRELIMINAR DA REDE NEURAL
RELACIONADA A SENSIBILIDADE E ESPECIFICIDADE**

Classe	Sensibilidade	Especificidade	Distância
Floresta	0.5977	0.9964	0.4023
Sucessão Secundária Avançada	0.2970	0.9910	0.7030
Sucessão Secundária Inicial	0.6019	0.9982	0.3931
Pasto Limpo	0.5314	0.9977	0.4686
Pasto Sujo	0.4499	0.9671	0.5511
Cultua Agrícola	0.5833	0.9997	0.4167
Área Urbana	0.6884	0.9968	0.3116
Água	0.8725	0.9709	0.1308
Nuvem	0.5397	0.9818	0.4607
Sombra	0.8848	0.9880	0.1158

A última coluna da Tabela 3 apresenta a distância do par (sensibilidade, especificidade) relativas ao ponto (1,1), sendo que a maior distância indica um menor desempenho da rede.

5. CONCLUSÃO

A utilização da lógica fuzzy na rotulação de segmentos de imagem tem possibilitado “modelar” os diferentes níveis de ocorrência de cada classe temática. A utilização do atributo espectral juntamente com o textural e o contextual acenam como uma grande ferramenta para o levantamento e monitoramento do uso da terra.

6. REFERÊNCIAS

- Barbosa V.C; R.J. Machado and F.dos S. Liporace. “A neural system for deforestation monitoring on Landsat Images of the Amazon Region”. Technical Report CCR-157, IBM, Rio Scientific Center, October 1993. 38p.
- Liporace. F. dos S. “Um sistema neural para monitoração do desflorestamento na região Amazônica utilizando imagens do Landsat”. Maste’s Thesis, Universidade Federal do Rio de Janeiro, Brasil, 1994. 123p.
- Machado. R. J; V.C. Barbosa; F. dos S. Liporace; J.R dos Santos; A. Venturieri. “Deforestation monitoring of the Amazon region using neural networks - a comparasion between differents photo-interprets and networks”. In: Proceedings os ISPRS Comission VII Symposium - Resource and Enviromental Monitoring. Sept. 26-30, 1994. Rio de Janeiro, Brasil. v.30. part 7b. p.49-55.

- Santos, J. R dos; A. Venturieri; R. J. Machado; F. dos S. Liporace. "Monitoring land use based on image segmentation and neural networks". In: IGARSS'95. July. Firenze. v.1. p.108-111.
- Schoenmakers. R.P.H.M; G.G. Wilkinson and Th. E. Schoutem. "Segmentation of remotely-sensed images: a redefinition for operational applications". In: IGARSS'91. June, 1991. Finland. v.2. p.1087-1090.

Héctor Sánchez Sánchez,
 Craig J. Weigand,
 Gerald J. Anderson,
 IMTA, A.P. 302, Interoac. Mor. C.P. 62220,
 FUSDAVARS, 2413 E. Hwy 83,
 Weslaco, Tx 78768-8344, U.S.A.

RESUMEN

En este estudio se utilizó a las imágenes de satélite para identificar la salinidad del suelo y estimar la pérdida de rendimiento del trigo (*Triticum aestivum*) durante el ciclo de siembra otoño-primavera 1993-1994, en el Distrito de Riego 076 Valle del Carrizo, Sinaloa, México, el cual es una zona con problemas de salinidad en el suelo. En la etapa de floración del trigo, se hizo la toma de una imagen Landsat TM y una imagen Spot Panorámica. En parcelas de trigo afectadas por las sales se establecieron puntos de observación para medir la salinidad del suelo y el rendimiento de grano. De la imagen Landsat se extrajeron los contornos digitales de las bandas TM2, TM3 y TM4 de los puntos de observación cuyos valores se correlacionaron con los datos de campo. Ello permitió obtener ecuaciones de regresión para estimar la salinidad y el rendimiento de grano de todos los píxeles del área sembrada con trigo. Se realizó una clasificación no supervisada de la subimagen de la imagen Spot, digitalizada previamente en la imagen Spot. Los valores medios de las firmas espectrales se sustituyeron en las ecuaciones de regresión para disponer de valores estimados de salinidad y rendimiento, que al aplicarlos en la imagen georreferenciada de valores estimados de salinidad y rendimiento, se determinó que por un mapa de clases de salinidad y un mapa de clases de rendimiento de trigo. Se determinó que por efecto de la salinidad se están dejando de producir 10,000 toneladas de trigo, aproximadamente.

1. INTRODUCCION

En México las áreas de producción agrícola que presentan problemas de salinidad se localizan principalmente en los Distritos de Riego (DR) del norte del país. Debido a que los DR son las áreas agrícolas más productivas, la salinidad es considerada un problema serio debido a que el 30% del área total de trigo del país está afectada por las sales en diferentes grados (Pulido, 1994). Esta situación es la causa de que se obtengan rendimientos más bajos, se reduzca la infraestructura hidroagrícola y se produzca desempleo entre otras consecuencias (Fernández, 1990).

Para conocer el impacto económico en las superficies agrícolas de los DR afectadas por la salinidad, es necesario el conocimiento de la cantidad y ubicación de las superficies de estos problemas, así como tener información de la pérdida de rendimiento ocasionada por la salinidad en los principales cultivos que se producen en los distritos de riego. Este conocimiento permitirá orientar las estrategias de acción para la recuperación de los suelos con mayores problemas, mediante obras de drenaje, prácticas de lavado y aplicación de mejoradores y de esa forma reincorporar los terrenos a la producción (Weigand, 1994; Pulido, 1993). Del mismo modo facilita la toma de decisiones sobre cuáles cultivos sembrar en las áreas afectadas, si se considera que los cultivos difieren entre sí por su tolerancia a la salinidad (Ayres y Wescoat, 1987).

En el diagnóstico de la salinidad se han utilizado tecnologías modernas entre las que se mencionan el uso de sensores remotos como una herramienta viable para obtener mapas de salinidad en escala pedánea (Pulido, 1993). Entre estas tecnologías las imágenes de satélite, la videografía y la fotografía aérea infrarroja destacan por las ventajas que ofrecen (Weigand et al, 1992a, 1992b, 1993, 1994a,b).