

CLASSIFICAÇÃO CONTEXTUAL DE IMAGENS MULTIESPECTRAIS

JORGE A. SILVA CENTENO
Pesquisador RHA/CNPq
Núcleo Estadual de Meteorologia e
Recursos Hídricos /CDCT/SEPLAN-AL
R. Cincinato Pinto 503, Edif SETOR 2o. andar
Centro - Maceió - AL

VITOR HAERTEL
Professor IPH/UFRGS
Centro Estadual de Pesquisa em Sensoriamento
Remoto e Meteorologia/UFRGS
Av. Bento Gonçalves 9500
Campus do Vale - Porto Alegre - RS

ABSTRACT -- This study applies contextual attributes to improve the accuracy of the Gaussian Maximum Likelihood classification of remote sensing images. Therefore, the probabilistic relaxation is tested. Relaxation processes start making a first estimate of the probabilities that relate each pixel to the classes considered in the classification. This estimates are then iteratively updated using the compatibility coefficients. An alternative procedure is introduced, in which the probability values are first filtered using a low-pass filter and then the probabilistic relaxation is used. Tests with synthetic images and real LANDSAT scenes confirm that the accuracy of the classification can be incremented using contextual information.

INTRODUÇÃO

São várias as maneiras de implementar o processo de classificação de imagens digitais. Os métodos mais comumente empregados se baseiam na informação espectral, ou seja, nos valores do contador digital em cada uma das bandas que representam a energia proveniente dos objetos na porção do terreno correspondente a cada pixel. Desta forma, são deixados de lado aspectos fundamentais da interpretação de imagens, como por exemplo: a forma, textura, posição relativa ou tamanho dos objetos na imagem.

Gong e Howart 1990, comentam que as técnicas de classificação digital de imagens de satélite (como por exemplo a classificação pelo método da Máxima Verossimilhança Gaussiana) produzem, frequentemente, resultados menos precisos que aqueles obtidos através da interpretação humana. Isto se deve ao fato dos algoritmos de computador não incluírem em seus processos a exploração de outros atributos das imagens além dos espectrais. Atributos espaciais (forma, textura) e contextuais

não são considerados, o que prejudica a classificação, pois não são analisadas todas as fontes de informação na imagem, como seria feito pelo cérebro humano.

Por este motivo, são buscados novos processos de classificação capazes de incluir outros atributos além dos atributos espectrais, que permitam explorar ao máximo a informação contida na imagem e facilitar as atividades de monitoramento e inventário dos recursos naturais através de sensoriamento remoto. No presente trabalho, são desenvolvidas metodologias, baseadas em processos de relaxação, que visam incluir os atributos contextuais dentro do processo de classificação de imagens digitais. A finalidade deste estudo é aumentar a precisão da classificação de imagens pelo método da Máxima Verossimilhança Gaussiana através da inclusão do conceito de contexto no processo de classificação.

REVISAO BIBLIOGRÁFICA

Pesquisas anteriores no campo da exploração dos

atributos de contexto tem mostrado que o contexto é uma fonte rica em informação muito útil na classificação dos pixels que formam a imagem. Uma das contribuições mais significativas é o trabalho de Landgrebe (1980), quem desenvolveu ECHO (Extraction of Homogeneous Objects), um classificador que é considerado eficiente na identificação de objetos cujas dimensões são superiores à resolução espacial do sensor utilizado para registrar a imagem. Em ECHO, a cena é inicialmente dividida em pequenos segmentos homogêneos mediante testes estatísticos. Estes segmentos são posteriormente agrupados através de um teste de similaridade estatística, chegando-se a formar grupos maiores pela combinação de segmentos similares. Assim, os grupos crescem até o ponto em que o teste de similaridade não é satisfeito, o que deve ocorrer quando os limites naturais dos objetos são atingidos.

Outra abordagem é utilizada por Moller-Jensen (1990), quem desenvolveu uma metodologia que visa incluir o conhecimento heurístico no processo de classificação de imagens digitais de sensoriamento remoto em áreas urbanas. O método proposto consiste em dividir inicialmente a imagem em pequenas áreas utilizando um algoritmo de detecção de bordas e linhas. Assim, a imagem é dividida em grupos de pixels espacialmente delimitados pelas linhas da imagem. Cada grupo de pixels é então classificado considerando suas características espectrais, sua textura e contexto. Nesta etapa, cada grupo de pixels é tratado como sendo uma unidade, representada espectralmente pelo vetor de médias e a matriz de covariância dos números digitais obtidos a partir de todos os pixels que formam o grupo. O contexto de cada grupo é definido pelos grupos vizinhos e a distância a alguns pontos significativos dentro da imagem, como por exemplo o centro da cidade ou centros comerciais.

Os processos de relaxação têm também sido utilizados para introduzir o conceito de contexto no processo de classificação. Os processos de relaxação modificam iterativamente uma estimativa inicial da classificação (desconhecida) dos pixels na imagem mediante o uso dos pixels na vizinhança como fonte de informação. Rosenfeld et al. (1976) descreve uma técnica que usa o contexto, através da correlação existente entre a classificação de pixels adjacentes. Zucker et al. (1978) propõe o uso da probabilidade condicional da co-ocorrência de classes entre pixels vizinhos como forma de incluir a informação contextual na classificação.

Outras variações do algoritmo de Rosenfeld et al. são também propostas por Eklundh et al. (1980), Richards et al. (1980) e Di Zenzo et al. (1989a e 1989b).

METODOLOGIA

Landgrebe (1980) constatou que os valores do contador digital de pixels espacialmente próximos estão altamente correlacionados entre si e que esta correlação decresce na medida em que a distância entre os pixels aumenta. A distribuição espacial dos objetos em uma cena natural de sensoriamento remoto não é aleatória. Geralmente, objetos de mesma natureza tendem a formar grupos ou pelo menos a ficar próximos entre si dentro da imagem. Considerando que a distribuição espacial dos objetos não é constante e que ela varia de imagem para imagem, a quantidade de informação que pode ser extraída a partir do contexto depende do grau de precisão com que esta relação contextual pode ser estimada.

A informação contextual encontra-se associada à relação entre a resposta espectral de um pixel e sua vizinhança imediata. Em uma imagem digital, o contexto pode ser estimado a partir de um grupo de pixels chamado de "janela móvel". Segundo é definido em Swain et al. (1981), o contexto de um pixel é formado pelo conjunto de $(n-1)$ observações próximas, mas não necessariamente adjacentes, a ele. Estas $(n-1)$ observações servem como contexto espacial para o pixel e são tomadas na mesma posição espacial relativa para todos pixels possíveis dentro da imagem.

No presente trabalho, são utilizadas janelas quadradas de 3×3 e 5×5 pixels, por considerar que nelas a informação pode ser mais corretamente atribuída ao pixel central da janela devido ao fato da correlação ser invariante com relação à rotação da imagem. Para facilitar a compreensão das formulações que serão apresentadas a seguir, o pixel central será identificado pelo índice "i" e qualquer outro pixel dentro do contexto de "i" será representado pela letra "j" ($j = 1, 2, \dots, 7, 8$, no caso da janela 3×3). Um exemplo é apresentado na figura 1. Como acontece em outros processos que utilizam este tipo de janelas móveis, o contexto não pode ser definido para pixels nas bordas da imagem, pois nesses casos faltam pixels para completar a janela.

O processo de classificação trata de agrupar os indivíduos sob estudo dentro de uma das classes

possíveis. No caso da classificação de imagens digitais multiespectrais, os indivíduos são os pixels, descritos pelos vetores de estado que contêm os números do contador digital e as classes são aquelas de interesse do usuário.

Denotando por $X=(x_1, x_2, \dots, x_n)$ o conjunto de vetores de estado dos pixels e por $W=(w_0, w_1, \dots, w_m)$ o conjunto das classes de interesse, a classificação tem por finalidade decidir qual classe pode ser mais corretamente atribuída a cada pixel. A dimensão dos vetores é igual ao número de bandas que compõem a imagem multiespectral.

Uma metodologia consagrada na classificação de imagens em sensoriamento remoto é aquela baseada nos princípios de decisão de Bayes, conhecida como Máxima Verossimilhança Gaussiana. Nela, é assumida a normalidade de "X" e "W". Para classificar os pixels "x", são utilizadas funções discriminantes que representam o grau com que o vetor de estado "x" pode ser relacionado às classes em "W". Os parâmetros utilizados para definir as classes são o vetor de médias $\mu(h)$ e a matriz de covariância da classe $\Sigma(h)$.

Considerando um pixel "i", as funções discriminantes assumem a seguinte formulação para a classe genérica "h":

$$D(h) = \sqrt{A} * \exp(-0.5 * B) \quad (1)$$

onde:

$$A = \frac{p}{(2 * \pi)^p \det(\Sigma(h))}$$

$$B = (x - \mu(h))' C (x - \mu(h))$$

C= matriz invertida de $\Sigma(h)$ (dimensão p x p)

p= número de bandas da imagem multiespectral

π = constante "pi" ≈ 3.1416

$\mu(h)$ = vetor de médias da classe "h"

$\Sigma(h)$ = matriz de covariância da classe "h"

det(): operador matricial "determinante"

exp(): função exponencial

$(x - \mu(h))'$ = vetor transposto de $(x - \mu(h))$

D(h)= função discriminante associada à classe "h".

O pixel é atribuído à classe cujo valor da função discriminante seja o maior ao longo de "W".

A RELAXAÇÃO PROBABILÍSTICA

O processo da relaxação probabilística aqui adotado é similar ao descrito em Di Zenzo (1989a).

Como em imagens de sensoriamento remoto geralmente ocorrem grupos de pixels para os quais não se dispõe de uma função densidade de probabilidade, ou que não são de interesse na classificação, existe a necessidade de se criar um artifício que agrupe estes pixels dentro de uma "classe" única, que aqui será chamada de "fundo". Ela não é uma classe, no sentido próprio da palavra, mas este artifício é utilizado para compensar a falta de conhecimento a respeito destes pixels e a satisfazer a condição do somatório das probabilidades que relacionam o pixel "i" às classes em "W" ser igual à unidade.

Devido ao carácter não convencional da classe "fundo", não é possível estabelecer sua função discriminante. Esta situação é contornada pela simplificação de Di Zenzo et al. (1989a) que adota um valor constante para esta função, igual ao máximo valor que a função densidade de probabilidade, para qualquer classe "h", assume na fronteira da região de confiança definida pela estatística de T-Hotelling para um grau de significância pré-definido.

O processo da relaxação probabilística proposto por Rosenfeld et al. (1976) é um processo iterativo que se serve da informação contextual obtida na vizinhança do pixel para ajustar o valor destas probabilidades. Todo o processo pode ser descrito da seguinte forma: utilizando um classificador espectral (por exemplo: o da Máxima Verossimilhança Gaussiana), é feita uma primeira classificação da imagem. Assim, para cada pixel "i" é estimado o valor das probabilidades $p(i, h)$ associadas às classes "h". Estas probabilidades devem ser superiores a zero e menores à unidade. Além disso, o somatório das probabilidades de todas as classes deve ser igual à unidade.

Estas estimativas iniciais são então ajustadas pelo processo de relaxação utilizando uma função contextual que relaciona as probabilidades $p(i, h)$ com as probabilidades dos pixels vizinhos $p(j, k)$ dentro da janela móvel definida como contexto. Esta função contextual se baseia na compatibilidade do par ("i \in h" e "j \in k"). A relação contextual assume a seguinte forma:

$$p(i, h, t+1) = F(h, q(i, W, t)) \quad (2)$$

Onde "t" representa os passos do processo iterativo e $q(i, W, t)$ significa a contribuição do contexto no valor da probabilidade no passo "t".

Inicialmente, os valores das probabilidades

que relacionam os pixels às classes, que são desconhecidos, devem ser estimados.

A maneira aqui adotada para obter a primeira estimativa das probabilidades é através da classificação pelo método da Máxima Verossimilhança. Este método foi escolhido porque ele fornece uma boa aproximação dos valores desconhecidos de $p(i,h)$ e ele considera a distribuição e rotação espectral de cada classe no processo de classificação.

A equação 1 pode ser utilizada para calcular as probabilidades. Para satisfazer a condição do somatório das probabilidades que relacionam o pixel "i" às classes em "W" ser igual à unidade, é necessário fazer uma normalização da seguinte forma:

$$p(i,h,0) = \frac{p(i,h,0)}{\sum_{k=0}^n p(i,k,0)} \quad (3)$$

A contribuição da vizinhança $q(i,W,t)$, segundo proposto por Rosenfeld et al., pode ser representada por:

$$q(i,W,t+1) = \sum_{j=1}^n \sum_{k=0}^n d(i,j) * r(j,h,k) * p(j,k,t) \quad (4)$$

Onde:

$d(i,j)$ é um coeficiente que representa a influência da posição relativa "j" na classificação de "i".

$r(j,h,k)$ é o coeficiente de compatibilidade do evento "Classe "h" ocorre no pixel "i" ao mesmo tempo que a classe "k" ocorre na posição relativa "j" da janela".

$p(j,k,t)$ é a probabilidade do pixel "i" pertencer à classe "h" ao mesmo tempo que o pixel na posição relativa "j" da janela pertence à classe "k", no passo "t" do processo iterativo.

Assumindo que $d(i,j)$ tenha valor constante para todos os vizinhos na janela, a relação contextual pode ser escrita da forma:

$$p(i,h,t+1) = p(i,h,t) \{1 + (1/8) * SS\} \quad (5)$$

Onde:

$$SS = \sum_{j=1}^n \sum_{k=0}^n (d(i,j) * r(j,h,k) * p(j,k,t))$$

Esta formulação da relaxação probabilística não é suficiente para manter os valores das probabilidades dentro do intervalo de zero a um, assim que é necessária a normalização destes valores:

$$p(i,h,t+1) = p(i,h,t) * (1/L) \{1 + (1/8) * SS\} \quad (6)$$

Onde:

$$L = \sum_{k=0}^n p(i,h,t) \{1 + (1/8) * SS\} \quad (7)$$

Os valores do coeficiente de compatibilidade devem ser restritos ao intervalo entre (-1,1). O efeito da combinação de $r(j,h,k)$ e $p(j,k,t)$ no valor da probabilidade associada ao pixel central $p(i,h,t+1)$ deve ser o seguinte: $p(i,h,t+1)$ deve ser incrementado se a vizinhança tem altos valores das probabilidades e elas são altamente compatíveis com $p(i,h,t)$. Por outro lado, $p(i,h,t+1)$ deve ser diminuído se a vizinhança apresentar altos valores da probabilidade e a compatibilidade entre o pixel central e a vizinhança for baixa. Caso os valores das probabilidades sejam baixos, a vizinhança não deverá ter efeito sobre o valor de $p(i,h,t+1)$.

Segundo Peleg et al. (1977), o coeficiente de compatibilidade deve ter as seguintes propriedades:

$r(j,h,k) > 0$ se "h" e "k" forem compatíveis em "i" e "j";

$r(j,h,k) < 0$ se "h" e "k" não forem compatíveis em "i" e "j";

$r(j,h,k) \approx 0$ se "h" e "k" forem independentes.

Rosenfeld et al. sugere que o coeficiente de compatibilidade pode ser obtido a partir da correlação estatística. Uma abordagem diferente para definir o coeficiente de compatibilidade é aquela baseada no conceito de informação mútua da classificação de pixels adjacentes, sugerida por Peleg et al. (1978). Ela satisfaz os requisitos do coeficiente de compatibilidade: se duas classificações têm alta correlação positiva, é de se esperar que elas tenham também alta informação mútua. A informação mútua entre ("i" e "h" e "j" e "k") pode ser escrita da seguinte forma:

$$I(i,j,h,k) = \log((n * p(i,h,j,k)) / (p(i,h) * p(j,k))) \quad (8)$$

O termo "n" representa o número total de pixels na imagem e é uma constante para todas as possíveis combinações de "k" e "h", pelo que será

ignorado. Com esta simplificação, a expressão (8) pode ser utilizada como coeficiente de compatibilidade. As probabilidades necessárias para definir $I(i,j,h,k)$ não são conhecidas em uma imagem de sensoriamento remoto, motivo pelo qual elas devem ser estimadas. A classificação obtida pelo método da Máxima Verossimilhança Gaussiana pode ser também utilizada para estimar estas probabilidades. Isto é efetuado contando o número de vezes que cada classe acontece na imagem classificada, considerando sua posição relativa dentro da janela.

$$p(i \in h, j \in k) = N(j, h, k) / n \quad (9)$$

$$p(i \in h) = \sum_{j=1}^n N(j, h, k) / n \quad (10)$$

Onde $N(j, h, k)$ representa o número de vezes que a classe "h" aparece na posição "i" da janela e a classe "k" ocorre na posição "j". Assim, o coeficiente de compatibilidade assume a forma:

$$r(j, h, k) = I(i, j, h, k) / r(j, h, k) = \log((n * N(j, k, k)) / (SPK1 * SPK1)) \quad (11)$$

Com:

$$SPH1 = N(j, 0, k) + N(j, 1, k) + \dots + N(j, m, k)$$

$$SPK1 = N(j, h, 0) + N(j, h, 1) + \dots + N(j, h, m)$$

Como não há necessidade de valores extremos para o coeficiente de compatibilidade, é assumido que os eventos que originam valores da informação mútua fora da faixa $(e-5, e+5)$ podem ser ignorados (Peleg et al. 1978, Eklundh et al. 1980).

Eklundh et al. (1980) sugere que um critério para fixar o ponto final do processo iterativo da relaxação pode ser derivado a partir da taxa média de variação entre duas iterações sucessivas. Segundo Zucker et al. (1981), a taxa média de variação para o processo de relaxação deve convergir a um valor constante. A taxa média de variação (TMV) para duas iterações sucessivas $(t, t+1)$ pode ser calculado pela seguinte fórmula:

$$TMV = (1/n) \sum_{h=1}^m \sum_{i=1}^n (p(i, h, t+1) - p(i, h, t)) \quad (12)$$

PROCESSO COMBINADO DE FILTRAGEM ESPACIAL E RELAXAÇÃO PROBABILÍSTICA

Segundo comentado acima, a correlação entre pixels

especialmente próximos existe em cenas naturais de sensoriamento remoto. A co-ocorrência de classes em pixels próximos espacialmente é determinada pelas características da cena. Cenas homogêneas tendem a apresentar baixos valores para a probabilidade conjunta $p(i \in h, j \in k)$, com $h < k$.

Neste trabalho é adotada a seguinte simplificação: em se tratando de áreas homogêneas $p(i \in h, j \in k)$ tende a ser muito próxima de $p(i \in h)$, ou seja, o valor de $p(i \in h, j \in k)$ é tende a a ser muito pequeno para h diferente de k. O resultado desta simplificação é uma forma mais rígida do coeficiente de compatibilidade: $r(j, h, k) = 1$ se $h = k$ e $r(j, h, k) = 0$ se $h < k$.

Assim, a formulação apresentada para a relaxação probabilística na equação (5) pode ser escrita da seguinte forma:

$$q(i, w, t+1) = \sum_{j=1}^8 (d(i, j) * r(j, h, k) * p(j, k, t)) \quad (13)$$

O que corresponde à formulação matemática de um processo de filtragem efetuado no domínio das probabilidades. Como mencionado anteriormente, a classificação contextual tem por finalidade eliminar "outliers" em áreas homogêneas. Por conseguinte, uma forma de implementar o conceito de contexto é através do uso de filtros do tipo passa baixas sobre os valores estimados das probabilidades $p(i, h)$.

A filtragem passa-baixas pode ser efetuada diretamente no domínio espacial pela convolução da imagem com uma janela móvel. Neste trabalho, janelas 3x3 e 5x5 foram empregadas (figura 2). Devido que o valor de $d(i, j)$ representa a influência que a posição "j" tem sobre o valor do pixel central, algumas janelas usam maiores valores de $d(i, j)$ para os pixels mais próximos do centro da janela.

A simplificação drástica introduzida no processo pode conduzir a melhores classificações dentro de áreas homogêneas, mas também é capaz de causar erros na imagem temática resultante, especialmente nas regiões de fronteiras entre classes.

A relaxação probabilística é utilizada para corrigir tais erros. A relaxação probabilística efetuada após a filtragem espacial não considera a simplificação do coeficiente de compatibilidade, evitando assim o favorecimento das áreas homogêneas

e o prejuízo das bordas entre classes. O uso do coeficiente na sua forma original, derivada a partir do conceito de informação mútua, é necessário para levar em consideração a co-ocorrência de diferentes classes em pixels adjacentes e assim diminuir os erros utilizando a compatibilidade entre classes. A melhor forma de estimar a compatibilidade entre classes diferentes é ainda a obtida a partir da imagem classificada pelo método da Máxima Verossimilhança Gaussiana, pois a filtragem espacial introduz erros significativos nas áreas de fronteira, que é precisamente onde pode ser estimada a co-ocorrência de classes diferentes.

TESTES

Os algoritmos acima apresentados foram codificados para seu uso no sistema de tratamento de imagens SITIM-150/INPE utilizando linguagem C e as rotinas do sistema SITIM-150.

IMAGENS SINTÉTICAS:

Inicialmente, foram gerados dados para formar imagens sintéticas com a finalidade de melhor avaliar o ganho obtido na precisão através da implementação do conceito de contexto em relação à classificação não contextual.

Três bandas (50x50 pixels) foram geradas para a constituição de imagens multiespectrais. Foi assumida a distribuição normal para as classes distribuídas na imagem. Os parâmetros utilizados para definir as características espectrais das classes foram portanto o vetor de médias e a matriz de covariância de cada classe, que foram obtidos a partir de valores estimados em uma imagem real LANDSAT-TM da bacia do Rio Potiribú/RS.

Para fins de classificação, foram escolhidas amostras nas imagens sintéticas, de forma a poder definir os parâmetros empregados no cálculo das funções discriminantes do método da Máxima Verossimilhança Gaussiana. O nível de significância para o processo foi fixado em $\alpha=10\%$.

Com estes dados, foram calculadas as funções discriminantes, as quais, após serem normalizadas, foram discretizadas em 8 bits. Estes valores foram armazenados de maneira espacialmente ordenada, com o que se obteve "bandas de probabilidade", uma para cada classe.

Os processos acima apresentados foram testados nestas imagens, do que se deduziram valiosas considerações que orientaram os testes em imagens

reais.

IMAGENS REAIS:

A imagem utilizada para teste corresponde a uma área da bacia do Rio Potiribú, no estado de Rio Grande do Sul, Brasil. Trata-se de uma imagem LANDSAT-TM, bandas 3,4 e 5, obtida no dia 17 de abril de 1989. Três dias antes foi realizado um voo com helicóptero sobre a área de forma a se obter fotografias oblíquas, as quais serviram para identificar melhor os alvos sobre o terreno e obter a verdade de campo necessária para avaliar os resultados da classificação.

Os processos de classificação contextual foram testados em partes escolhidas desta imagem. Um exemplo é aqui apresentado para ilustrar os resultados obtidos. Trata-se de uma pequena área com 54x40 pixels. Nela, as classes que foram identificadas como predominantes e de interesse são: "vegetação densa", "pastagens" e "campos de soja ocupados por resteva". Os valores das probabilidades "a priori" das classes para a classificação espectral pelo método da Máxima Verossimilhança Gaussiana foram considerados iguais. O nível de significância para esta classificação foi fixado em 10%.

RESULTADOS

No caso das imagens sintéticas a evolução da matriz de confusão foi monitorada ao longo do processo. Nela, a soma dos elementos na diagonal principal representa o número de classificações corretas após cada iteração. Assim, a precisão foi calculada para cada passo do processo iterativo. Isto só foi possível em imagens sintéticas, onde a verdadeira classificação de cada pixel é conhecida.

As tabelas 1 e 2 mostram a evolução do valor da taxa média de variação e a precisão para uma série de testes utilizando os processos da relaxação probabilística e o combinado da filtragem espacial e relaxação probabilística com uma imagem sintética. Na figura 3 são mostradas as imagens resultantes destes processos.

Os valores da taxa média de variação mostram uma tendência convergente para a relaxação probabilística, na medida em que a precisão é aumentada a cada iteração. Nota-se que maior número de iterações não aumenta significativamente a precisão.

O processo combinado de filtragem espacial das probabilidades seguido pela relaxação

probabilística demonstrou ser eficiente. O valor da precisão neste algoritmo é aumentado, sendo que o filtro tipo 3, mostrado na figura 2, está associado aos melhores resultados.

A iteração escolhida para deter o processo da relaxação probabilística é quando a diferença do valor da taxa média de variação entre duas iterações sucessivas for inferior a 0.003. Este valor foi derivado a partir dos resultados obtidos com imagens sintéticas.

A tabela 4 mostra um resumo da evolução da taxa média de variação do processo da relaxação probabilística para uma imagem real.

O processo combinado de filtragem espacial e relaxação probabilística utilizado nas imagens reais foi implementado com o filtro tipo 3, mostrado na figura 2.

A figura 4 mostra os resultados obtidos através destes dois processos. Nota-se o maior grau de homogeneização resultante em ambos processos. No entanto, uma análise detalhada da imagem e sua comparação com as observações de campo constata que o processo que utiliza a filtragem espacial é capaz de trabalhar eficientemente dentro de áreas homogêneas, mas causa perda de detalhes na imagem classificada. Os grupos de pixels de mesma classe de pequeno porte não são preservados, embora estejam classificados corretamente pelo classificador espectral da Máxima Verossimilhança. Isto não acontece no processo da relaxação probabilística, que por ser mais suave preserva melhor a informação espectral.

CONCLUSÕES

Os resultados dos experimentos têm comprovado que é possível melhorar a classificação digital de imagens de sensoriamento remoto, através da inclusão do conceito de contexto no processo de classificação, e tornar as imagens temáticas resultantes mais apropriadas para interpretação visual. Isto pode tornar mais fácil seu uso em estudos de monitoramento e inventário da cobertura vegetal em recursos hídricos.

No caso da relaxação probabilística, o aumento da precisão é observado mais claramente nos testes com imagens sintéticas, que podem ser considerados experimentos controlados, ou seja, onde a verdadeira classificação dos pixels é conhecida "a priori".

Os experimentos também mostraram que no caso de imagens reais, é necessário um maior número de

iterações para atingir o valor pré-estabelecido da taxa média de variação que para o processo. Isto se justifica do ponto de vista da distribuição espacial das classes nas imagens. Nas imagens sintéticas as classes estão distribuídas formando grandes áreas em relação ao tamanho da imagem. Já nas imagens reais isto não acontece, pois a região escolhida apresenta uma grande mistura de campos de cultivo, em vários estágios de desenvolvimento. Isto é refletido nos valores estimados do coeficiente de compatibilidade, que por sua vez influenciam a taxa média de variação após cada iteração.

Como o processo de filtragem não é iterativo, ele consome menor tempo de execução em relação ao da relaxação probabilística, mas produz resultados menos precisos. No entanto, a imagem resultante obtida após a filtragem espacial é muito bem corrigida por uma iteração da relaxação probabilística. O resultado obtido mostra a eficiência deste método em se tratando de áreas homogêneas.

Apesar do sucesso atingido com a metodologia desenvolvida, deve-se chamar a atenção ao fato dela requerer um elevado tempo de processamento, que aumenta na medida em que a área de estudo for maior. O balanço entre a precisão e o custo em tempo de processamento definem a estratégia mais apropriada para cada finalidade. Existem situações que exigem um conhecimento mais detalhado da cobertura vegetal em bacias, onde os processos contextuais podem ser vantajosamente empregados. Da mesma forma, existem situações onde um estudo com menor grau de precisão é suficiente.

A informação que pode ser obtida a partir da exploração dos atributos de contexto depende da maneira e precisão com que a relação contextual entre classes pode ser estimada. No presente estudo, esta relação foi implementada na forma de coeficientes de compatibilidade. Esta não é a única solução existente, mas demonstrou ser eficiente para a finalidade pretendida. O ganho obtido com a informação contextual significa maior precisão na classificação e, portanto, a estimativa de parâmetros relacionados à cobertura do solo torna-se mais fácil e eficiente.

REFERENCIAS BIBLIOGRÁFICAS

- DI ZENZO, S., DE GLORIA S.D., BERNSTEIN R. e KOLSKY H.G. (1989a), Gaussian Maximum Likelihood and Contextual Classification Algorithms for Multicrop

- Classification. IEEE Transactions on Geoscience and Remote Sensing, Vol GE 25, No. 6, Novembro de 1987. pp.805-814.
- DI ZENZO, S., DE GLORIA S.D., BERNSTEIN R. e KOLSKY H.G. (1989b), Gaussian Maximum Likelihood and Contextual Classification Algorithms for Multicrop Classification Experiments Using Thematic Mapper on Multispectral Scanner Sensor Data. IEEE Transactions on Geoscience and Remote Sensing, Vol GE 25, No. 6, Novembro de 1987. pp.815-824.
- EKLUNDH, J.O., YAMAMOTO H. e ROSENFELD A. (1980). A Method for Multispectral Pixel Classification. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. PAMI-2, No. 1, Janeiro de 1980. pp 72-75.
- GONG, P. e HOWARTH, P.J. (1990). An Assessment of Some Factors Influencing Land-Cover Classification. Photogrammetric Engineering and Remote Sensing, Vol. 56, No. 5. pp.597-603.
- HSIAO, J.Y. e SAWCHUK, A.A. (1980). Supervised Textured Image Segmentation Using Feature Smoothing and Probabilistic Relaxation. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol PAMI-11, No. 1, p.p 1279-1291.
- LANDGREBE, D.A. (1980). The Development of a Spectral-Spatial Classifier for Earth Observational Data. Pattern Recognition, Vol.12, pp.165-175.
- MOLLER-JENSEN, L. (1990). Knowledge-based Classification of an Urban Area Using Texture and Contextual Information in Landsat TM Imager. Photogrammetric Engineering and Remote Sensing, Vol. 56, No. 6. pp.899-904.
- PAL S. e DWIJESH, D.M. (1986). Fuzzy Mathematical Approach to Pattern Recognition. Nova York U.S.A. John Willey & Sons, Cap. 1,2.
- PELEG, S. e ROSENFELD A. (1978). Determining Compatibility Coefficients for Curv Enhancement Relaxation Processes. IEEE Transactions on, Systems Man and Cybernetics, Vol. SMC-8, No.7. pp.548-555.
- RICHARDS, J.A., LANDGREBE, D.A. e SWAIN P.H. (1980). Pixel Labeling by Probabilistic Relaxation. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. PAMI-2, No. 1. pp 1808-1815.
- ROSENFELD, A., HUMMEL, R. e ZUCKER S.W. (1976). Scene Labeling by Relaxation Operations. IEEE Transaction on Systems, Man and Cybernetics, Vol. SMC-6, No.6. pp.420-433.
- SWAIN P.H., VADERMAN, S.B. e TILTON J.C. (1981). Contextual Classification of Multispectral Data. Pattern Recognition, Vol.13, No.6. pp 429-441.
- TILTON, J.C., VADERMAN, S.B. e SWAIN P.H. (1982). Estimation of Context for Statistical Classification o Multispectral Image Data. IEEE Transactions on Geoscience and Remote Sensing. Vol. GE.20, No.4. pp 445-452.
- ZUCKER S.W., KRISHNAMURTHY, E.V. e HAAR, R.L. (1978) Relaxation Processes for Scene Labelling: Convergence, Speed and Stability IEEE Transactions on Systems, Man and Cybernetics, Vol. SMC-8. No.5. pp.41-48.

TABELAS

TABELA 1 - Entropia, taxa média de variação e precisão obtidos através do processo da relaxação probabilística aplicado à imagem sintética.

Iteração	ENTROPIA	Taxa média de variação	Precisão
0			0.488
1	0.074862	0.037611	0.9636
2	0.058701	0.024634	0.9708
3	0.046644	0.018255	0.9772
4	0.037628	0.013780	0.9820
5	0.030765	0.010560	0.9864
6	0.025479	0.008102	0.9872
7	0.021333	0.006333	0.9888
8	0.018178	0.004938	0.9904
9	0.015581	0.003852	0.9920
10	0.013577	0.002916	0.9916

TABELA 3 - Entropia e taxa média de variação obtidos através do processo da relaxação probabilística aplicado a uma imagem real.

Iteração	ENTROPIA	Taxa média de variação
0	0.098159	
1	0.091244	0.012992
2	0.087283	0.009877
3	0.083668	0.009372
4	0.080357	0.008989
5	0.077094	0.008547
8	0.067472	0.006616
10	0.062647	0.005661
15	0.052825	0.004278
20	0.044629	0.003292
22	0.041802	0.002889

TABELA 2 - Entropia e precisão obtidas através do processo combinado de filtragem espacial (filtro tipo 3) e relaxação probabilística aplicado à imagem sintética.

Iteração	ENTROPIA	Precisão
0		0.9488
Filtro tipo 3	0.074862	0.9636
Relaxação Probabilística	0.058701	0.9708

FIGURAS

j=1	j=2	j=3
j=8	"i"	j=4
j=7	j=6	j=5

FIGURA 1 - Exemplo de janela móvel 3x3 utilizada como contexto do pixel "i".

1	1	1	1	1
1	1	1	1	1
1	1	1	1	1
1	1	1	1	1
1	1	1	1	1
1	1	1	1	1

Filtro Tipo 1

1	1	1
1	1	1
1	1	1

Filtro Tipo 2

1	2	1
2	4	2
1	2	1

Filtro Tipo 3

FIGURA 2 - Exemplos de janelas móveis testadas no processo de filtragem espacial.




FIGURA 3 - Imagens temáticas obtidas em experiências com imagens sintéticas.
 (a) imagem original;
 (b) relaxação probabilística e
 (c) processo combinado de filtragem e relaxação probabilística.

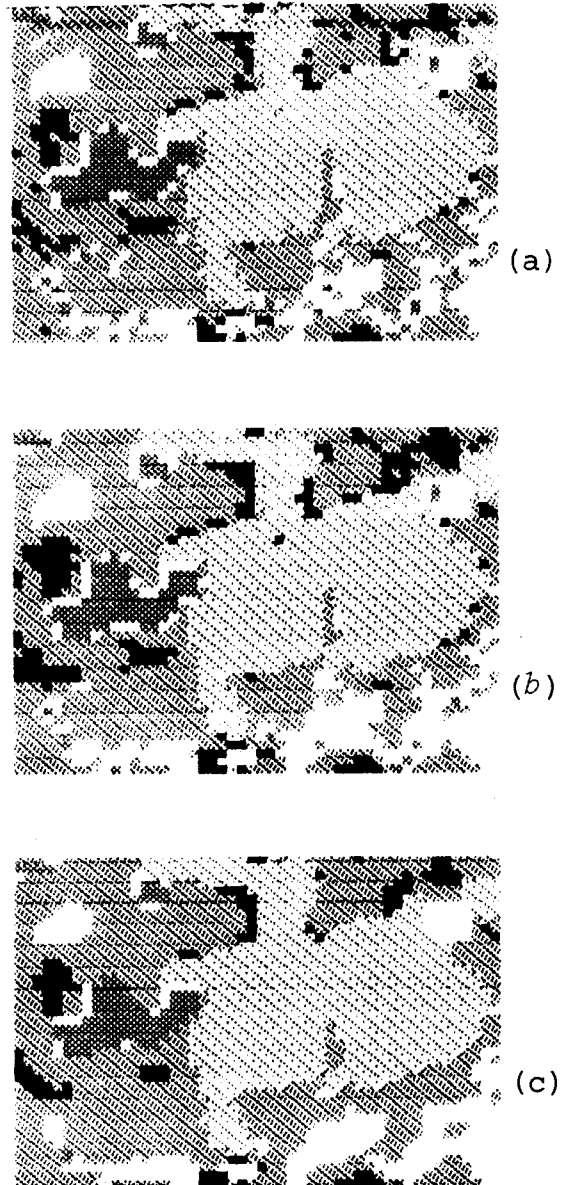


FIGURA 4 - Imagens temáticas obtidas em experiências com imagens reais.
 (a) imagem original;
 (b) relaxação probabilística e
 (c) processo combinado de filtragem e relaxação probabilística.