

IMPLEMENTAÇÃO COMPUTACIONAL DE CLASSIFICADORES DIGITAIS: APLICAÇÃO NA CARACTERIZAÇÃO DE AMBIENTES PANTANEIROS

Silvio Jacks dos Anjos Garnés¹

¹UNIDERP – Programas de Mestrados em Meio Ambiente e Desenvolvimento Regional e Produção e Gestão Agroindustrial – Pesquisador da Fundação Manoel de Barros - silviojacks@mail.uniderp.br

RESUMO

Este trabalho apresenta os usuais classificadores de imagens digitais com sub-routines em linguagem computacional Matlab e uma aplicação prática dos métodos implementados numa região pantaneira do Estado de Mato Grosso do Sul. Os resultados mostram a importância de se confrontar vários classificadores a fim de melhor interpretar unidades de paisagem. Alertam também sobre possíveis engodos de classificações quando o interprete desconhece as variações de paisagens ocorrentes nestes ambientes.

Palavras-chave: Pantanal, Classificação, Imagem digital

IMPLEMENTATION OF DIGITAL CLASSIFIERS : APPLICATION IN THE CHARACTERIZATION OF ENVIRONMENT SWAMPY

ABSTRACT

This work presents the usual classifiers of digital images with subroutines in Matlab and a practical application of the methods implemented in a region of the swampland of the State of Mato Grosso do Sul. The results point out the importance of confronting several classifiers in order to best to interpret units of landscape in the swampland. They also alert on possible mistakes of classifications when the interpreter ignores the variations of landscapes that happen in these places.

Keywords: Swampland, Classification, Digital Image

1. INTRODUÇÃO

A tecnologia de geração de dados por sensoriamento remoto vem permitindo que o meio físico da Terra possa ser estudado e compreendido em sua complexidade e dinâmica, mas vem exigindo também, uma maior integração de conhecimentos. Neste contexto, muitos áreas do conhecimento ganharam destaques, em particular, a de geração de aplicativos, pois sem os quais a tecnologia ficaria restrita as interpretações visuais de algumas décadas passadas.

A captura de dados de ambientes por sensores remotos, incluindo-se aí, as fotos analógicas e digitais, são provenientes das radiações dos elementos que possuem calor, emitindo radiação em sua própria frequência, ou são provenientes da reflexão da radiação do sol e/ou de uma fonte artificial. Assim, se a radiação estiver no intervalo do espectro eletromagnético no qual o sensor opera, a energia é de alguma forma convertida em informação que poderá ser visualizada por algum meio. Se a representação for digital, em geral, será transformada em um número representado na forma binária de um byte, podendo ter $2^8 = 256$ combinações de oito bits. Para cada combinação é associado um número denominado tom de cinza, sendo os valores desse tom de cinza de 0 (cor preta) a 255 (cor branca).

O meio físico, embora contínuo, tem sua representação em tela discreta por meio de pixels (elementos de figura), cujos tons de cinza são derivados dos valores médios das respostas espectrais obtidas da área de abrangência/correspondência de cada pixel. O arranjo em linhas e colunas (matriz) dos pixels com os tons de cinza associados, forma uma imagem digital. Os sistemas de sensores chamados multiespectrais são capazes de captar informações de determinados intervalos (bandas) do espectro eletromagnético e formar para cada banda uma imagem digital com características próprias das

respostas dos alvos.

Atualmente, existem sistemas com sensores capazes de captar 224 bandas, como é o caso do AVIRIS (*Airborne Visible and Infrared Imaging Spectrometer*), 210 bandas como o caso do HYDICE (*Hiperespectral Digital Imagger Collection Experiment*) (MOREIRA, 2003). No entanto, entre os sistemas usados no Brasil, se destaca por popularidade o Landsat, que iniciou suas atividades em 1972 com o nome de ERTS (*Earth Resources Technology Satellite*), hoje no sétimo da série, o Landsat 7; o SPOT (*Système Probatoire d'Observation de la Terre*), iniciado em 1986 e o programa CBERS (*China-Brazil Earth Resources Satellite*), iniciado em 1988.

Embora os sensores possam captar informações de várias bandas; do ponto de vista de informação para uma classificação, isto é, atribuir rótulos para áreas homogêneas numa imagem, a correlação entre bandas podem ser muito acentuadas e não acrescentar para uma diferenciação efetiva das classes. Neste caso, algumas técnicas estatísticas podem ser utilizadas para se ter as bandas mais representativas, menos correlacionadas, como por exemplo, usando as técnicas por análise de componentes principais ou por análise de correlação canônica.

Partindo desta premissa, os algoritmos apresentados no decorrer deste trabalho fazem uso de apenas três bandas, posto que os mesmo, podem ser aplicados em imagens digitais geradas por escaneamento de fotografias, resultantes em três bandas, composição colorida RGB (vermelho, verde e azul). Todavia, para trabalhos com mais de três bandas, bastaria uma simples adaptação.

2. AMBIENTE DA APLICAÇÃO

As aplicações práticas dos métodos foram realizadas em uma imagem *Enhanced Thematic Mapper-ETM+* Landsat 7, de uma área do Pantanal brasileiro, mais especificamente no Estado de Mato Grosso do Sul, na sub-região do Negro, onde se encontra instalado o Instituto de Pesquisa do Pantanal da UNIDERP-IPPAN, na fazenda Santa Emília .

A cena completa foi formada pela composição RGB das bandas ETM+ 5, 4 e 3 e recortada para contemplar apenas a área de estudo (fig. 1).



Figura 1 - Imagem ETM⁺ Landsat 7 - 225/074, 24/04/2000 – Fazenda Santa Emília
Período de vazante na sub-região do Negro

Nesta região do Pantanal brasileiro as variações de paisagens naturais e antrópicas encontradas com maior frequência são: cordilheiras, capões, baías, lagoas, corixos, rios, campo sazonalmente inundado, mata ciliar e pastagens algumas destas unidades estão indicadas na figura 1.

Do ponto de vista sócio econômico para o homem pantaneiro, é muito importante que sua propriedade possua grandes extensões com pastagens nativas, uma vez que a criação de gado de corte é sua principal fonte de renda. Mas, por outro lado, é importante também que se tenha áreas conservadas de beleza cênica natural, ricas em fauna e flora para a exploração do turismo ecológico, atividade crescente no Estado, notadamente no Pantanal.

Com o uso da classificação, uma propriedade pode ser mapeada e suas unidades quantificadas. Podendo, por exemplo, o pecuarista realizar o seu plano de manejo com base na classificação, pois saberia a capacidade de carga de sua propriedade: três, quatro, cinco ou mais cabeças de gado por hectare. Classificações realizadas nos períodos de cheia (janeiro a março), vazante (abril a junho), seca (julho a setembro) e enchente (outubro a dezembro) permitiriam um planejamento ainda mais rigoroso, pois na seca a área de pastagem aumenta em relação a época da cheia.

3. CLASSIFICADORES DIGITAIS

Os classificadores digitais são métodos estatísticos ou não, transformados em algoritmos, os quais têm por meta distinguir em imagens digitais com base no tom de cinza de um pixel ou de uma região de pixels, a classe, num conjunto finito de classes, a qual pertence o pixel sob análise.

Existem duas formas distintas de atuação de um classificador, aqueles que têm por base um grupo de pixels como amostra da classe e aqueles que não possuem amostras para classificar o pixel. Estas duas formas são conhecidas, respectivamente, como classificação supervisionada e classificação não-supervisionada.

Dentre os classificadores que trabalham com classificação supervisionada foram abordados neste trabalho: o classificador do paralelepípedo; o classificador da distância euclidiana; o classificador distância de mahalanobis e o classificador da máxima verossimilhança. Dentre os classificadores que trabalham com classificação não-supervisionada, segundo CENTENO (2003), o mais utilizado é o ISODATA, motivo pelo qual foi escolhido para ser implementado.

3.1 CLASSIFICAÇÃO SUPERVISIONADA

3.1.1. Classificador do Paralelepípedo

Escolhida uma amostra de uma região da imagem, encontra-se o tom de cinza mais escuro e o mais claro dessa amostra, isto é, o menor e o maior valor. Isto feito para as três bandas, ter-se-á um espaço de atributos tridimensional.

Com um intervalo de aceitação em cada banda forma-se um paralelepípedo neste espaço. Varrendo-se a imagem, o pixel que pertencer ao paralelepípedo pertencerá a classe amostrada.




Figura 2 - Espaço de Atributos Tridimensional

Se a classificação for realizada iterativamente não haveria confusão na tomada de decisão do classificador, porque um pixel já classificado, assumiria a tonalidade de sua temática.

O intervalo entre o menor e o maior valor dos tons de cinza poderia ser substituído pelo intervalo dado pela média e desvio padrão da amostra, ou um múltiplo do desvio padrão, tendo como base um intervalo de confiança estatístico.

Este classificador fica restrito às classes previamente definidas, assim se um pixel não pertencer a uma das classes pré-definidas, o mesmo não é classificado. Neste caso, pode-se usar o valor original da imagem ou uma classe geral como temática dos pixels que não se enquadram nas classes de interesse.

3.1.2. Classificador da Distância Euclidiana

A distância euclidiana entre dois pontos p_1 e p_2 de um espaço vetorial (ex. R^n) é definida como:

$$d_{p_1-p_2} = \| \mathbf{p}_1 - \mathbf{p}_2 \|_2, \quad (1)$$

onde:

$\| (\cdot) \|_2$: denota a norma-2 de vetor ou norma euclidiana (GILL; MURRAY e WRIGHT, 1991).

$\mathbf{p}_1 = [u_1 \ v_1 \ w_1]^T$; e $\mathbf{p}_2 = [u_2 \ v_2 \ w_2]^T$,

sendo: u_1, v_1, w_1 tons de cinza do ponto (vetor) \mathbf{p}_1 nas bandas 1, 2 e 3; e

u_2, v_2, w_2 tons de cinza do ponto (vetor) \mathbf{p}_2 nas bandas 1, 2 e 3.

O classificador da distância euclidiana consiste em medir a distância euclidiana no espaço de atributo tridimensional (ou n-dimensional) de um pixel (sua posição é definida pelas coordenadas dadas pelos tons de cinza em cada banda) até posição dos valores médios das classes amostrais previamente definidas. O ponto médio da classe que estiver mais próximo do pixel sob análise, no sentido da norma euclidiana mínima, é a classe a qual ele irá pertencer. E, assim, se pode atribuir a ele a tonalidade da temática pré-definida.

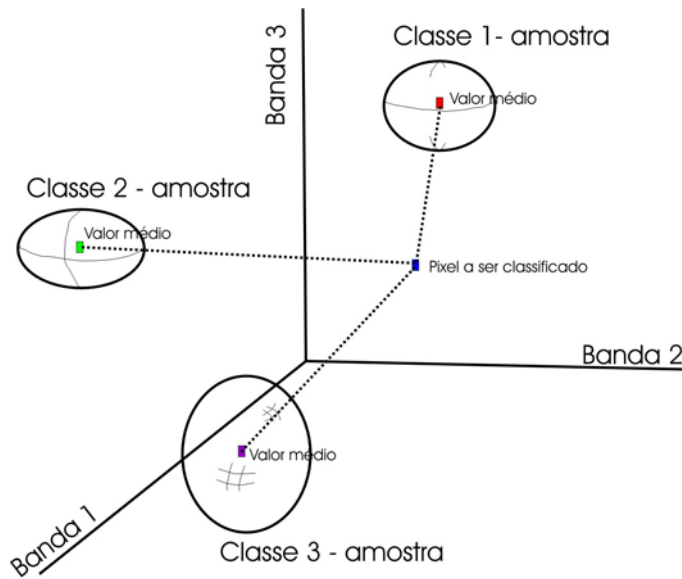


Figura 3 – Fundamento do Classificador da Distância Euclidiana

A figura 3 ilustra a geometria do classificador da distância euclidiana. Os elipsóides representam a região onde os pixels amostrados estão localizados, cujos centros são os valores médios. As linhas representam a ligação entre o pixel a ser classificado e os valores médios. A menor linha medida por meio da equação (1), indica a classe do pixel.

3.1.3. Classificador da Distância de Mahalanobis

A norma de vetor $\| (\cdot) \|$ em termos práticos é um instrumento de medida de comprimento de vetor, tendo o mesmo princípio da escala, dependendo da norma adotada, tem-se a medida da mesma grandeza numa ou noutra escala.

Se um vetor for pré-multiplicado por uma matriz, o vetor resultante poderá ser ampliado, reduzido ou rotacionado. Assim, considerando uma matriz \mathbf{W} e pré-multiplicando-a pelos vetores \mathbf{p}_1 e \mathbf{p}_2 e substituindo os vetores resultantes na equação (1), tem-se a distância euclidiana entre estes dois vetores transformados, dada por:

$$d_{p_1-p_2} = \| \mathbf{W}\mathbf{p}_1 - \mathbf{W}\mathbf{p}_2 \|_2 = \| \mathbf{W}(\mathbf{p}_1 - \mathbf{p}_2) \|_2. \quad (2)$$

Da definição da norma-2 de vetor, o quadrado da distância $d_{p_1-p_2}$ pode ser escrito como:

$$(d_{p_1-p_2})^2 = \langle \mathbf{W}(\mathbf{p}_1 - \mathbf{p}_2), \mathbf{W}(\mathbf{p}_1 - \mathbf{p}_2) \rangle = (\mathbf{p}_1 - \mathbf{p}_2)^T \mathbf{W}^T \mathbf{W} (\mathbf{p}_1 - \mathbf{p}_2), \quad (3)$$

onde: $\langle \cdot, \cdot \rangle$ denota o produto interno de dois vetores.

Se o produto das matrizes $\mathbf{W}^T \mathbf{W}$ resultar numa matriz simétrica e definida positiva, então \mathbf{W} é o fator

triangular superior da decomposição de Cholesky dessa matriz. No entanto, se essa matriz for a inversa da matriz de covariância amostral (\mathbf{S}_i^{-1}), então a distância dada pela equação (3), torna-se:

$$(d_{p_1-p_2}) = [(\mathbf{p}_1-\mathbf{p}_2)^T \mathbf{S}_i^{-1} (\mathbf{p}_1-\mathbf{p}_2)]^{1/2}, \quad (4)$$

sendo conhecida na literatura estatística por distância de Mahalanobis (JOHNSON e WICHERN, 1988).

Para a aplicação da equação (4) na classificação, basta substituir o ponto \mathbf{p}_2 pelo valor médio (\mathbf{m}_i) da classe amostral (i) a ser verificada, usar a correspondente matriz de covariância (\mathbf{S}_i) dessa classe. E, \mathbf{p}_1 corresponderia ao vetor posição do pixel a classificar no espaço de atributos. O pixels pertencerá a classe cuja distância de mahalanobis for a menor entre \mathbf{p}_1 e \mathbf{m}_i .

A diferença em usar a distância de mahalanobis face a distância euclidiana está no fato da primeira levar com conta a correlação existente entre os pixels nas diferentes bandas da região amostral. Do ponto de vista computacional esta estratégia encarece o processo, porque cada pixel deverá ser multiplicado por uma matriz. Em cenas completas com milhões de operações, a diferença de tempo computacional pode se tornar um critério de decisão na escolha do classificador.

3.1.4. Classificador da Máxima Verossimilhança

O classificador da máxima verossimilhança (máxima probabilidade) utiliza como função discriminante a equação (5) (CENTENO, 2003):

$$\min g_j(\mathbf{p}) = \ln(|\mathbf{S}_j|) + (\mathbf{p}-\mathbf{m}_j)^T \mathbf{S}_j^{-1} (\mathbf{p}-\mathbf{m}_j), \quad \forall \mathbf{m}_j, \quad (5)$$

onde: \mathbf{p} : vetor posição do pixel sob análise;
 \mathbf{S}_j : matriz de covariância para a classe j;
 \mathbf{m}_j : valor médio da classe amostral j;
 $|\cdot|$: determinante de matriz; e
 \ln : logaritmo neperiano (natural).

Comparando-se a equação (5) e equação (4), verifica-se que neste método deve-se minimizar a distância de mahalanobis acrescida do determinante da matriz de covariância da classe.

Para se chegar na expressão do discriminante, equação (5), duas hipóteses iniciais foram tomadas; uma foi que a distribuição dos pontos do espaço de atributos é normal multivariada; e a outra é que o teorema de bayes é válido para as probabilidades condicionais ponto/classe e classe/ponto. A dedução detalhada do discriminante pode ser encontrada em (MIKHAIL; BETHEL e MCGLONE, 2001) e (CENTENO, 2003).

3.2 CLASSIFICAÇÃO NÃO-SUPERVISIONADA

Na classificação não-supervisionada, o classificador não dispõe a priori de amostras da imagem com temáticas conhecidas para iniciar seu processo de classificação. No entanto, é comumente fornecido o número total de classes. Geralmente apenas esse parâmetro é suficiente para automação do processo.

3.2.1. Classificador Isodata

Neste classificador verifica-se qual o ponto mais próximo e o mais afastado da origem do espaço de atributos, calcula-se a distância euclidiana (d) entre eles. Com o número total de classes fornecido (n) e a distância (d), calcula-se a distância que deverá ter um ponto médio do outro, para que a linha unindo o ponto mais próximo ao ponto mais afastado contenha (n+1) intervalos (fig. 4).

Procede-se a classificação de todos os pixels da imagem por um dos três últimos métodos de classificação supervisionada descritos na seção anterior, agrupando-se os pixels (espaço de atributos) em torno do valor médio. Recomenda-se neste caso, por ser o mais rápido, a utilização do classificador da distância euclidiana.

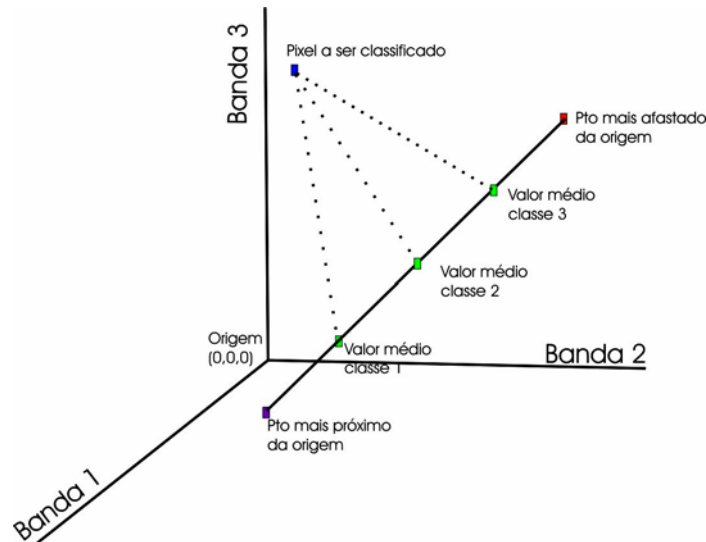


Figura 4 - Estabelecimento das Condições Iniciais do Classificador Isodata

Após uma primeira classificação em torno dos valores médios definidos ao longo da diagonal da imagem no espaço de atributos, calcula-se um novo valor médio para cada classe, que deverá ser diferente do valor médio inicialmente adotado (fig.5). Procede-se então, uma nova classificação da imagem original para os novos valores médios.

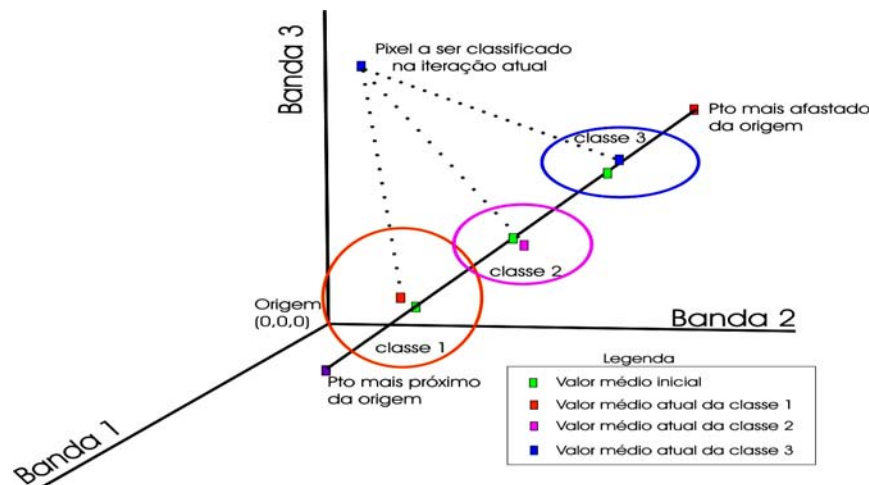


Figura 5 - Processo Iterativo do Classificador Isodata

As iterações devem continuar até que alguma condição de parada seja cumprida. Neste trabalho, adotou-se o seguinte critério de parada:

$$\text{Parar se: } \|\max_j (\mathbf{m}_{i-1} - \mathbf{m}_i)\|_2 \leq 1, \quad (6)$$

onde: \mathbf{m}_i e \mathbf{m}_{i-1} : são respectivamente os vetores médios da classe (i) na iteração atual e anterior; e \max_j : significa a máxima diferença entre as classes utilizadas.

A condição dada pela equação (6) implica em aceitar a classificação como final, quando o máximo deslocamento dos pontos médios no espaço de atributos entre duas iterações sucessivas for igual ou inferior a uma posição.

4. IMPLEMENTAÇÃO COMPUTACIONAL

As implementações computacionais dos classificadores anteriormente descritos foram elaboradas na linguagem Matlab, onde se fizeram uso de algumas funções disponíveis no toolbox de processamento de imagem que acompanha o pacote. Em particular, três dessas funções foram indispensáveis. A primeira, **imread**, lê uma imagem digital nos formatos mais comuns jpg, tif, gif e bmp e a transforma numa matriz tridimensional de tons de cinza; a segunda, **roipoly**, permite selecionar um polígono na imagem retornando as posições (coordenadas de tela) dos pixels selecionados; e a terceira, **imshow**, permite a visualização da imagem formada pela matriz tridimensional de tons de cinza na tela do computador.

A implementação foi toda desenvolvida como uma **function** do matlab e denominada **imclassificasj**. A função **imclassificasj** é apresentada na sua íntegra no apêndice deste trabalho, e para ser executada no matlab bastaria transcrevê-la ou copiá-la e salvá-la com o nome **imclassificasj.m**, ir no ambiente do matlab no diretório onde a mesma foi salva, digitar **imclassificasj** e teclar <enter>.

Notas de crédito:

As rotinas não inerentes ao matlab foram todas elaboradas pelo autor, de maneira que os créditos de seu uso deverão ser atribuídas ao autor com referência a este artigo.

5. RESULTADOS

A seguir são apresentadas as classificações realizadas pelo programa (apêndice), conforme a seqüência descrita na seção 3, isto é: paralelepípedo (fig.6) ; distância euclidiana (fig.7); distância de mahalanobis (fig.8); máxima verossimilhança (fig.9) e Isodata (fig.10). Destas classificações, apenas a classificação usando o classificador do paralelepípedo não apresenta o percentual da temática na legenda. Isto porque, não foi implementada a contagem dos pixels. Também, neste classificador quando um pixel não se enquadra às classes amostrais, optou-se por recuperar os pixels da imagem original.

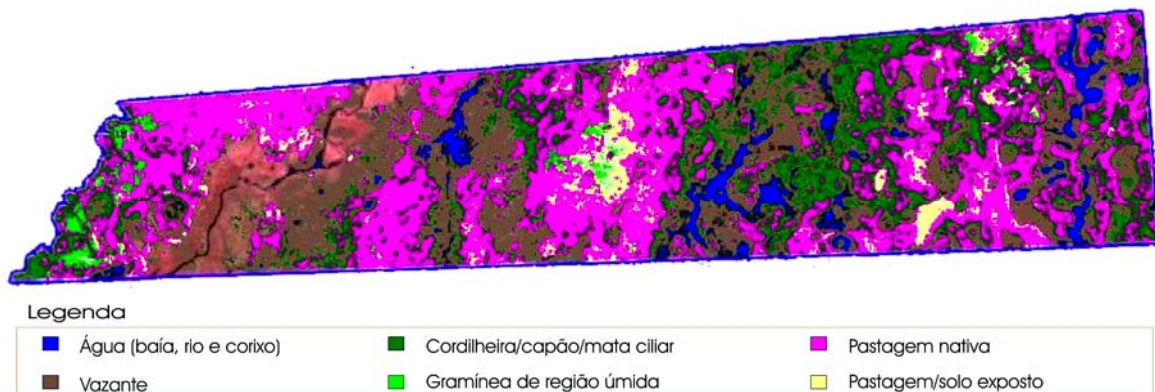


Figura 6 - Classificação pelo Classificador do Paralelepípedo





Figura 7 - Classificação pelo Classificador da Distância Euclidiana



Legenda




Figura 8 - Classificação pelo Classificador da Distância de Mahalanobis






Figura 9 - Classificação pelo Classificador da Máxima Verossimilhança



Legenda



Figura 10 - Classificação pelo Classificador Isodata

6. ANÁLISE DOS RESULTADOS E CONSIDERAÇÕES FINAIS

6.1. ANÁLISE DOS RESULTADOS

No presente trabalho foram desenvolvidos e aplicados cinco métodos de classificação digital de imagem. Com base na imagem (fig.1) e no conhecimento *in loco* da área por visitas periódicas durante os três últimos anos em projetos de pesquisa de monitoramento do nível d'água de baías (GARNÉS et al., 2003), de levantamento da mastofauna (mamíferos) com desenvolvimento de transectos a pé, a cavalo, de barco e com veículos (MAMEDE e GARNÉS, 2003) e, até mesmo, com a realização de sobrevôo da área, é que se pode dar créditos às classificações realizadas e, ao mesmo tempo, ficar alerta a possíveis engodos que uma classificação às pressas pode conduzir. Por exemplo, por que existem grandes diferenças nos percentuais das temáticas obtidas entre os vários classificadores, sendo a área de estudo a mesma? Para o caso específico, algum dos classificadores apresentados é mais fiel à realidade? Para iniciar essa discussão chama-se a atenção para os temas utilizados. Analisando a fig.1, distingue-se claramente as águas em preto; as vazantes em marrom; as matas em verde; com um pouco mais de esforço se distingue um tom verde claro com tendência ao amarelo que são as gramíneas nas bordas das baías; um tom amarelo claro caracteriza gramínea de pastagem nativa; o tom mais claro na imagem corresponde a área onde foi construída a sede da fazenda e as instalações do IPPAN - na época da imagem as construções ainda estavam em fase inicial. Hoje o espaço ocupado continua o mesmo, mas a infra-estrutura foi ampliada e no local também foi instalada a Pousada Araraúna, a qual contribuiu para a sustentabilidade do empreendimento como um todo, dando oportunidade a turistas e pesquisadores do Brasil e do exterior em conhecer melhor o Pantanal.

Do lado esquerdo do rio Correntoso (fig.1) há uma espaço destacado como campo sazonalmente inundado, de fato, naquela localidade as águas inundam a superfície por mais de seis meses. O acesso até o rio Negro só é possível em seca extrema, pois caso contrário, mesmo a cavalo só se consegue avançar uns três quilômetros além do rio Correntoso.

Na classificação pelo paralelepípedo percebe-se que as águas das baías, rios e das vazantes quando ocorreu a classificação foram representadas adequadamente, todavia os demais temas não ficaram bons, a pastagem nativa foi evidenciada demais, abrangendo até mesmo parte de áreas mais elevadas e secas de cordilheiras. Registrou-se também a presença de solo exposto ou pastagem degradada do lado esquerdo do rio Correntoso, não sendo esta temática, típica daquele local.

Na classificação pela distância euclidiana verifica-se que todos os temas foram classificados muito próximo do adequado.

Na classificação pela distância de mahalanobis verifica-se uma classificação adequada das vazantes (marrom) e das gramíneas (verde claro), os demais temas não foram adequadamente classificados.

Na classificação pela máxima verossimilhança a água foi melhor classificada em relação a classificação pela distância de mahalanobis, no entanto as vazantes ficaram evidenciadas além do esperado. Os demais temas não foram adequadamente classificados, principalmente o de cor amarelo claro, cujo aumento foi muito considerável.

Na classificação pelo Isodata uma modificação na legenda teve que ser elaborada pelo fato de não se conhecer a priori como resultaria a classificação. Desde modo, procedeu-se a mudança da tonalidade representando cordilheira, para o verde claro, e a tonalidade magenta, passou a representar gramíneas de áreas úmidas e pastagem natural. Os restantes dos temas estão muito próximos do adequado.

Com o georreferenciamento da imagem pôde-se calcular a área total, resultando 2.716 ha. Com este valor pôde-se resumir as áreas de cada tema conforme indicado na tabela 1.

Tabela 1 – Resumo das áreas das temáticas classificadas

Classificador	Águas	Vazantes	Matas	Gramíneas	Solo exposto
Dist. Euclidiana	151,3 ha	920,7 ha	594,8 ha	1006,0 ha	39,7 ha
Isodata	200,7 ha	657,3 ha	1279,2 ha	537,8 ha	41,0 ha
Mahalanobis	28,2 ha	722,5 ha	460,9 ha	1423,2 ha	84,2 ha
Máxima ver.	72,8 ha	893,6 ha	567,6 ha	988,6 ha	198,3 ha

6.2. CONSIDERAÇÕES FINAIS

Embora os classificadores da distância euclidiana e Isodata aparentemente tenham tido melhores resultados em relação aos demais, as discrepâncias entre áreas das temáticas (tab. 1) não permitiram concluir favoravelmente a nenhum deles, e nem usar tal resultado no planejamento de atividades da propriedade. Isto mostra que usando imagens de satélite com resolução espacial de 30 m, o analista

intérprete deve ter cautela redobrada quando o objeto de estudo for classificação de ambientes pantaneiros. Recomenda-se para este tipo de ambiente, a utilização de imagens de sensores com maior resolução ou então fotografias aéreas.

7. REFERÊNCIAS BIBLIOGRÁFICAS

CENTENO, J. A. S. **Sensoriamento Remoto e Processamento de Imagens Digitais**. Curitiba: Departamento de Geomática, Universidade Federal do Paraná, 2003.

GARNÉS, S. J. A.; KRUEGER, C. P. ; MERCANTE, M. A.; MELLO, V. A. de. Caracterização Volumétrica da Baía dos Catetos no Pantanal Sul-Mato-Grossense, In.: III COLÓQUIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS, Curitiba – PR: Curso de Pós-Graduação em Ciências Geodésicas, 6 a 9 de maio de 2003.

GILL, P. E.; MURRAY, W. ; WRIGHT, M.H. **Numerical Linear Algebra and Optimization**. v.1. Redwood City, California: Addison-wesley publishing company, 1991.

JOHNSON, R. A.; WICHERN, D. W. **Applied Multivariate Statistical Analysis**. Englewood Cliffs: Prentice Hall international, Inc., 1988.

MAMEDE, S. B.; GARNÉS, S. J. A. A Geodésia e a Topografia como Suporte ao Estudo da Mastofauna e na Definição e Controle de Transectos: Estudo de Caso no IPPAN. **Ensaio e Ciência**, Campo Grande, v.7. ed. Especial, p. 579 – 586, set. 2003.

MIKHAIL, E. M.; BETHEL, J. S.; MCGLONE, J. C. **Introduction to Modern Photogrammetry**. New York: John Wiley & sons, Inc., 2001.

MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. 2. ed. Viçosa: Editora UFV, Universidade Federal de Viçosa, 2003.

8. AGRADECIMENTO

À UNIDERP e à Fundação Manoel de Barros pelo apoio financeiro e logística durante a pesquisa desenvolvida no projeto “Estudos limnológicos dos ecossistemas aquáticos do IPPAN: subsídios ao manejo e conservação” e em particular à minha colega de trabalho Profa. Dra. Mercedes Abid Mercante pelas valiosas sugestões no texto.

9. APÊNDICE

function imclassificasj

```
% CLASSIFICACAO DE IMAGEM DIGITAL SUPERVISIONADA e NAO-SUPERVISIONADA
clc
disp(' ')
disp(' CLASSIFICACAO DE IMAGEM DIGITAL ')
disp(' Copyrigh mar-2004 Prof. Silvio Jacks dos Anjos Garnes')
disp(' Laboratorio de Geoprocessamento da UNIDERP')
disp(' ');disp(' ');disp(' ')

nome=input('Nome da imagem a ser classificada ? ','s');
bw1=imread(nome); % transforma a imagem em matriz tridimensional de tons de cinza
m=size(bw1,1); % numero de linhas da imagem
n=size(bw1,2); % numero de colunas da imagem
disp(' ');
figure, imshow(bw1) % mostra a imagem colorida em uma nova figura
disp(' ');
disp(' OPCAO DE CORES - PODEM SER DEFINAS CLASSES COM AS SEGUINTES CORES : ')
disp('<1> amarelo' )
disp('<2> amarelo-claro' )
disp('<3> magenta' )
disp('<4> rosado' )
disp('<5> ciano' )
disp('<6> vermelho' )
disp('<7> alaranjado' )
disp('<8> laranja-claro' )
disp('<9> verde-claro' )
disp('<10> verde-escuro' )
disp('<11> azul-escuro' )
disp('<12> azul-claro' )
disp('<13> marrom' )
disp('<14> marrom-claro' )
disp('<15> branco' )
disp('Entre com as opcoes de cores para os temas que deseja classificar conforme o exemplo a seguir')
vetorcores=input('exemplo para o vetor de entrada: [2 8 9] ? '); % essa entrada define tambem o numero de classes
```

```

nclasse=length(vetorcores); % nclasse: e o numero de classes a serem definidas na imagem
disp(' '); disp(' ')
disp(' CLASSIFICACAO SUPERVISIONADA')
disp(' OPCAO DO METODO DE CLASSIFICACAO (CLASSIFICADOR)');
disp(' ');
disp('<1> Paralelepipedo' )
disp('<2> Distancia Euclidiana' )
disp('<3> Distancia de Mahalanobis')
disp('<4> Maxima Verossimilhanca' )
disp(' '); disp(' ')
disp(' CLASSIFICACAO NAO-SUPERVISIONADA')
disp(' OPCAO DO METODO DE CLASSIFICACAO');
disp(' ')
disp('<5> ISODATA' )
disp(' ');
metodo=input('Qual metodo ? ');

switch metodo
case 1,
bw3=bw1; % a matriz bw2 recebe a matriz bw1 para combinar a dimensao
bw3(:,:,1)=0; bw3(:,:,2)=0; bw3(:,:,3)=0; % bw3 e uma imagem totalmente preta
for k=1:nclasse
cor=corclasse(vetorcores(k)); % retorna o vetor RGB da selecao correspondente
Tcinza=matrizTcinza(bw1,m,n); % retorna a matriz com os tons de cinza para as 3 bandas de um
% poligono selecionado na subfuncao matrizTcinza

bw2=paralelepipedo(bw1,Tcinza,cor); % retorna bw2 preta e a cor selecionada pelo metodo
bw3=acumulaclasses(bw2,m,n,bw3); % retorna bw3 com as classes acumuladas
end
bw3=restaurasemclasse(bw1,m,n,bw3); % coloca tons originais nao classificados
figure, imshow(bw3) % mostra a imagem classificada
title('IMAGEM CLASSIFICADA PELO METODO DO PARALELEPIPEDO')
case 2,
for k=1:nclasse
Tcinza=matrizTcinza(bw1,m,n); % retorna a matriz com os tons de cinza para as 3 bandas de um vetor
MEDIA(k,:)=mean(Tcinza); % com os valores medios das colunas correspondentes da matriz Tcinza

end
[bw2,contapixels]=distanciaeuclidiana(bw1,MEDIA,m,n,vetorcores); % retorna bw2 preta e a cor selecionada pelo metodo
figure, imshow(bw2) % mostra a imagem classificada
title('IMAGEM CLASSIFICADA PELO METODO DA DISTANCIA EUCLIDIANA')
percentual_classificacao=100*contapixels/(m*n) % resultado em percentual das classes geradas
case 3,
t=0;
for k=1:nclasse
Tcinza=matrizTcinza(bw1,m,n); % obtem a matriz de tons de cinza
MEDIA(1,t+k:t+k+2)=mean(Tcinza); % media das classe
COVARIANCIA(:,t+k:t+k+2)=matrizCov(Tcinza); % matriz de covariancia das classes
t=t+2; % variavel auxiliar para incremento das colunas
end
[bw2,contapixels]=distanciamahalanobis(bw1,MEDIA,COVARIANCIA,m,n,vetorcores);
figure, imshow(bw2) % mostra a imagem classificada
title('IMAGEM CLASSIFICADA PELO METODO DA DISTANCIA DE MAHALANOBIS')
percentual_classificacao=100*contapixels/(m*n) % resultado em percentual das classes geradas
case 4,
t=0;
for k=1:nclasse
Tcinza=matrizTcinza(bw1,m,n); % obtem a matriz de tons de cinza
MEDIA(1,t+k:t+k+2)=mean(Tcinza); % media das classe
COVARIANCIA(:,t+k:t+k+2)=matrizCov(Tcinza); % matriz covariancia das classes
t=t+2; % variavel auxiliar para incremento das colunas
end
[bw2,contapixels]=maxverossimilhanca(bw1,MEDIA,COVARIANCIA,m,n,vetorcores);
figure, imshow(bw2) % mostra a imagem classificada
title('IMAGEM CLASSIFICADA PELO METODO DA MAXIMA VEROSSIMILHANCA')
percentual_classificacao=100*contapixels/(m*n) % resultado em percentual das classes geradas
case 5,
% Define a diagonal espectral
minimo(1,1)=min(min(bw1(:,1))); minimo(1,2)=min(min(bw1(:,2))); minimo(1,3)=min(min(bw1(:,3))); % minimo pto
espectral
maximo(1,1)=max(max(bw1(:,1))); maximo(1,2)=max(max(bw1(:,2))); maximo(1,3)=max(max(bw1(:,3))); % maximo pto
espectral
maximo=double(maximo);
minimo=double(minimo);
dx=maximo-minimo; % vetor de direcional da diagonal

```

```

dx=dx/(nclasse+1);      % intervalo para cada classe ao longo da diagonal
% define o vetor de medias para cada classe
t=0;
for k=1:nclasse
    MEDIA(k,.)=minimo+dx;
    dx=dx+dx/(nclasse+1);
    t=t+2;
end
% inicio do processo iterativo para a classificacao (ISODATA)
tol=1;      % tolerancia de parada para distancia entre medias
errormedia=10; % valor do erro para iniciar o processo iterativo
while errormedia>tol
    [MEDIA_N,dmedia,contapixels]=mediaeuclidiana(bw1,MEDIA,m,n,vetorcores);
    MEDIA=MEDIA_N;
    errormedia=norm(dmedia);
end % fim do processo iterativo
[bw2,contapixels]=distanciaeuclidiana(bw1,MEDIA,m,n,vetorcores); % retorna bw2 preta e a cor selecionada pelo metodo
figure, imshow(bw2) % mostra a imagem classificada
title('IMAGEM NAO-SUPERVISIONADA CLASSIFICADA PELO METODO ISODATA')
percentual_classificacao=100*contapixels/(m*n) % resultado em percentual das classes geradas
end

disp(' REALIZACAO DE FILTRAGEM ')
disp(' O processo de filtragem e demorado pode levar horas, recomenda-se utiliza-lo no refinamento final e nao em testes')
filtragem=input('filtrar a imagem classificada: <s> ou <n> ? ','s');
if filtragem=='s',
    disp('Aguarde o processamento; pode demorar um longo tempo !')
    bw2=processa_moda(bw2,3); % janela com 3x3 - filtra banda
    disp('Processamento realizado com sucesso !')
    figure, imshow(bw2) % mostra a nova imagem filtrada pelo filtro da moda
    title('IMAGEM POS-PROCESSADA PELO FILTRO DA MODA COM JANELA(3X3)')
end

% *****
function [MEDIA_N,dmedia,contapixels]=mediaeuclidiana(bw1,MEDIA,m,n,vetorcores)
% retorna os vetores de medias, novas, para a classificacao pela distancia euclidiana em relacao
% aos vetores de medias dmedia e a distancia entre as medias antigas com a nova classificacao
nclasse=length(vetorcores);
somaclasse=zeros(3,nclasse); % realiza a soma dos pixels nas classes
contapixels=zeros(1,nclasse); % conta o numero de pixel por classe
for i=1:m
    for j=1:n
        x(1,1)=bw1(i,j,1);
        x(1,2)=bw1(i,j,2);
        x(1,3)=bw1(i,j,3); % pixel a ser analisado
        x=double(x); % para permitir operacoes de subtracao
        for k=1:nclasse
            d(k)=norm(x-MEDIA(k,:)); % calculo das distancias em relacao as medias
        end
        [dmin,indice]=min(d); % verifica qual a menor distancia euclidiana e o seu indice
        % ira promover a soma a e contagem dos pixels por classe
        somaclasse(:,indice)=somaclasse(:,indice)+x';
        contapixels(1,indice)=contapixels(1,indice)+1;
    end
end
for k=1:nclasse
    MEDIA_N(k,.)=somaclasse(:,k)/contapixels(1,k); % nova media para a primeira classe
    dmedia(k,1)=norm(MEDIA_N(k,:)-MEDIA(k,:));
end

% *****
function [bw2,contapixels]=distanciaeuclidiana(bw1,MEDIA,m,n,vetorcores)
% retorna bw2 classificada de acordo com o criterio da menor distancia euclidiana
nclasse=length(vetorcores);
contapixels=zeros(1,nclasse); % conta o numero de pixel por classe
bw2=bw1;
for i=1:m
    for j=1:n
        x(1,1)=bw1(i,j,1);
        x(1,2)=bw1(i,j,2);
        x(1,3)=bw1(i,j,3); % pixel a ser analisado
        x=double(x); % para permitir operacoes de subtracao
        for k=1:nclasse
            d(k)=norm(x-MEDIA(k,:)); % calculo das distancias em relacao as medias
        end
        [dmin,indice]=min(d);
    end
end

```

```

        contapixels(1,indice)=contapixels(1,indice)+1; % faz a contagem dos pixels
        cor=corclasse(vetorcores(indice));
        bw2(i,j,1)=cor(1); % define a cor conforme a distancia
        bw2(i,j,2)=cor(2); % espectral do pixel em relacao a
        bw2(i,j,3)=cor(3); % media das amostras
    end
end

% *****
function [bw2,contapixels]=distanciamahalanobis(bw1,MEDIA,COVARIANCIA,m,n,vetorcores)
% classifica a imagem usando o criterio de proximidade da classe pela distancia de mahalanobis
nclasses=length(vetorcores);
contapixels=zeros(1,nclasses);
bw2=bw1;
t=0;
for k=1:nclasses % realiza a inversao dos blocos 3x3 de matrizes covariância
    S_1(:,t+k:t+k+2)=inv(COVARIANCIA(:,t+k:t+k+2));
    t=t+2;
end
for i=1:m
    for j=1:n
        x(1,1)=bw1(i,j,1); % colocando o pixel nas
        x(1,2)=bw1(i,j,2); % tres bandas
        x(1,3)=bw1(i,j,3);
        x=double(x); % passando para double para permitir operacoes de subtracao
        t=0;
        for k=1:nclasses
            d(k)=(x-MEDIA(1,t+k:t+k+2))*S_1(:,t+k:t+k+2)*(x-MEDIA(1,t+k:t+k+2)); % distancia de malahanobis da media ao pixel
            t=t+2;
        end
        [dmin,indice]=min(d); % encontra a menor distancia e mostra sua posicao ocupada no vetor
        contapixels(1,indice)=contapixels(1,indice)+1; % faz a contagem dos pixels
        cor=corclasse(vetorcores(indice));
        bw2(i,j,1)=cor(1); % define a cor conforme a distancia
        bw2(i,j,2)=cor(2); % espectral do pixel em relacao a
        bw2(i,j,3)=cor(3); % media das amostras
    end
end

% *****
function [bw2,contapixels]=maxverossimilhanca(bw1,MEDIA,COVARIANCIA,m,n,vetorcores)
% classifica a imagem pelo metodo da maxima verossimilhanca
nclasses=length(vetorcores);
contapixels=zeros(1,nclasses);
bw2=bw1;
t=0;
for k=1:nclasses
    S_1(:,t+k:t+k+2)=inv(COVARIANCIA(:,t+k:t+k+2)); % inversa da matriz de covariância
    determinante_S(1,k)=1/det(S_1(:,t+k:t+k+2)); % determinante da matriz de covariância S
    t=t+2;
end
for i=1:m
    for j=1:n
        x(1,1)=bw1(i,j,1); % colocando o pixel nas
        x(1,2)=bw1(i,j,2); % tres bandas
        x(1,3)=bw1(i,j,3);
        x=double(x); % passando para double para permitir operacoes de subtracao
        t=0;
        for k=1:nclasses % discriminante do metodo maxver
            g(k)=log(determinante_S(k)+(x-MEDIA(1,t+k:t+k+2))*S_1(:,t+k:t+k+2)*(x-MEDIA(1,t+k:t+k+2)));
            t=t+2;
        end
        [dmin,indice]=min(g); % encontra a menor distancia e mostra sua posicao ocupada no vetor
        contapixels(1,indice)=contapixels(1,indice)+1; % faz a contagem dos pixels
        cor=corclasse(vetorcores(indice));
        bw2(i,j,1)=cor(1); % define a cor conforme a distancia
        bw2(i,j,2)=cor(2); % espectral do pixel em relacao a
        bw2(i,j,3)=cor(3); % media das amostras
    end
end

% *****
function bw3=restaurasemclasse(bw1,m,n,bw3)
% restaura os tons de cinza nao classificados da imagem original
for i=1:m

```



```

for j=1:n
    if (bw3(i,j,1)==0 & bw3(i,j,2)==0)
        if bw3(i,j,3)==0
            bw3(i,j,1)=bw1(i,j,1);
            bw3(i,j,2)=bw1(i,j,2);
            bw3(i,j,3)=bw1(i,j,3);
        end
    end
end
end
end

%*****
function bw3=acumulaclasse(bw2,m,n,bw3)
% acumula cores diferentes na imagem conforme sua classificacao
for i=1:m
    for j=1:n
        if (bw2(i,j,1)~=0 | bw2(i,j,2)~=0)
            bw3(i,j,1)=bw2(i,j,1);
            bw3(i,j,2)=bw2(i,j,2);
            bw3(i,j,3)=bw2(i,j,3);
        end
        if bw2(i,j,3)~=0
            bw3(i,j,1)=bw2(i,j,1);
            bw3(i,j,2)=bw2(i,j,2);
            bw3(i,j,3)=bw2(i,j,3);
        end
    end
end
end

%*****
function cor=corclasse(k)
% As cores podem ser alteradas colocando sua tonalidade RGB no vetor cor
switch k
case 1, cor=[255 255 0];           % amarelo
case 2, cor=[242 242 158];       % amarelo-claro
case 3, cor=[255 0 255];         % magenta
case 4, cor=[235 199 203];       % rosado
case 5, cor=[0 255 255];         % ciano
case 6, cor=[255 0 0];           % vermelho
case 7, cor=[237 110 0];         % alaranjado
case 8, cor=[252 184 82];        % laranja-claro
case 9, cor=[0 255 0];           % verde-claro
case 10, cor=[0 150 0];          % verde-escuro
case 11, cor=[0 51 255];         % azul-escuro
case 12, cor=[82 156 181];       % azul-claro
case 13, cor=[141 117 105];      % marrom
case 14, cor=[153 112 89];       % marrom-claro
case 15, cor=[255 255 255];      % branco
end

% *****SUBFUNCOES METODOS *****
function bw2=paralelepipedo(bw1,Tcinza,cor)
% classificacao pelo metodo do paralelepipedo para 3 bandas da matriz bw1
limsupb1=max(Tcinza(:,1)); % limite superior do tom de cinza para a classificacao
liminfb1=min(Tcinza(:,1)); % limite inferior do tom de cinza para a classificacao
limsupb2=max(Tcinza(:,2)); % limite superior do tom de cinza para a classificacao
liminfb2=min(Tcinza(:,2)); % limite inferior do tom de cinza para a classificacao
limsupb3=max(Tcinza(:,3)); % limite superior do tom de cinza para a classificacao
liminfb3=min(Tcinza(:,3)); % limite inferior do tom de cinza para a classificacao
m=size(bw1,1); % numero de linha de bw1
n=size(bw1,2); % numero de colunas de bw1
bw2=bw1; % a matriz bw2 recebe a matriz bw1 para combinar a dimensao
bw2(:,1)=0; bw2(:,2)=0; bw2(:,3)=0; % bw2 e uma imagem totalmente preta
for i=1:m
    for j=1:n
        if bw1(i,j,1)>liminfb1 & bw1(i,j,1)<limsupb1,
            if bw1(i,j,2)>liminfb2 & bw1(i,j,2)<limsupb2,
                if bw1(i,j,3)>liminfb3 & bw1(i,j,3)<limsupb3,
                    % colorindo conforme selecao
                    bw2(i,j,1)=cor(1); % coloca a cor branca na primeira banda
                    bw2(i,j,2)=cor(2); % coloca a cor branca na segunda banda
                    bw2(i,j,3)=cor(3); % coloca a cor preta na terceira banda
                end
            end
        end
    end
end
end
end

```

end

% ----- SUBFUNCOES AUXILIARES -----

function [TCIN]=matrizTcinza(bw1,m,n)

% retorna a matriz de tons de cinza de um poligono selecionado

[Y,X,bw2,yi,xi]=roipoly(bw1); % seleciona um poligono na imagem bw2 e uma matriz binaria nas tres bandas
% dentro do poligono e 0 fora; y e x sao vetores com as coordenadas dos vertices do poligono
% busca na matriz mascara bw2 os tons de cinza correspondentes a regio interior ao poligono

k=0;

for i=1:m, % varia as linhas da imagem

for j=1:n,

if bw2(i,j)==1,

k=k+1;

% contagem do numero de pixels da classe correspondente

TCIN(k,1)=bw1(i,j,1); % matriz com os tons de cinza correspondentes aos pontos selecionados B1

TCIN(k,2)=bw1(i,j,2); % matriz com os tons de cinza correspondentes aos pontos selecionados B2

TCIN(k,3)=bw1(i,j,3); % matriz com os tons de cinza correspondentes aos pontos selecionados B3

end

end

end

% ***** fim da subfuncao matrizTcinza *****

function V=desviopad(X)

% retorna o desvio padrao de uma matriz ou de um vetor

% se X e uma matriz, V e um vetor com os desvios padrao das colunas

Y=double(X); % passando a dupla precisao para aceitar o sinal de " - "

n=size(Y,2); % determina quantas variaveis devem ser usadas no calculo do desvio padrao

m=size(Y,1); % determina o numero de elementos de cada variavel

l=ones(m,1); % vetor unitario

ME=(Y'*l)/m; % calcula a media de cada coluna

for j=1:n

residuo2=0;

for i=1:m

residuo2=residuo2+(Y(i,j)-ME(j))^2;

end

V(1,j)=sqrt((residuo2)/(m-1)); % desvio padrao

end

% ***** fim da subfuncao desviopad *****

function S=matrizCov(Tcinza)

% calcula a matriz covariancia a partir da matriz de dados Tcinza

T=double(Tcinza);

m=size(T,1); % numero de linhas da matriz Tcinza

S=(T*(eye(m,m)-ones(m,1)*ones(1,m)/m)*T)/(m-1);

% S=cov(T) % o calculo acima resulta identico a funcao cov do matlab

% V=diag(sqrt(S)) % fornece o vetor com os desvios padrao

% *****

function bw2=processa_moda(bw2,dimjanela)

% realiza um pos-processamento de filtragem pela moda da janela 3x3

% dimjanela e a dimensao da janela 3(3x3) ou 5(5x5) - deve ser impar

m=size(bw2,1); % numero de linhas da imagem

n=size(bw2,2); % numero de colunas da imagem

centro=round(dimjanela^2/2); % centro da janela na tabela de frequencia

bw3=bw2;

for banda=1:3

for i=2:m-(dimjanela-2)

for j=2:n-(dimjanela-2)

t=0;

r=0;

for k=1:(dimjanela^2)

% vetor com os elementos da janela

x(k)=bw3(r+i-1,t+j-1,banda);

t=t+1;

if t==dimjanela, t=0; r=r+1; end

end

% tabela de frequencia da janela

t=0;

while t<(dimjanela^2)

valor=x(t+1);

freq=1;

for k=1:(dimjanela^2)

if k==t+1,

if x(k)==valor, freq=freq+1; end

```
    end
  end
  t=t+1;
  tab(t,1)=valor;
  tab(t,2)=freq;
end
[maxfreq,indice]=max(tab(:,2));           % maxima frequencia e seu indice na tabela
moda=tab(indice,1);                       % moda para a janela ativa
if tab(centro,2)<=2 & maxfreq>=round(dimjanela^2/2), % se a frequencia do pixel
    bw3(i,j,banda)=moda;                   % atribui o valor da moda para o pixel central da janela
end
end
end
bw2(:,:,banda)=bw3(:,:,banda);
end
```