

Classificação Digital de Imagens de Sensoriamento Remoto: Tutorial Básico

Autores

Carlos Fernando Quartaroli

Mestre em Agronomia, Pesquisador da
Embrapa Monitoramento por Satélite
quarta@cnpm.embrapa.br

Mateus Batistella

PhD em Ciências Ambientais, Pesquisador da
Embrapa Monitoramento por Satélite
mb@cnpm.embrapa.br



*Empresa Brasileira de Pesquisa Agropecuária
Embrapa Monitoramento por Satélite
Ministério da Agricultura, Pecuária e Abastecimento*

*Dezembro, 2006
ISSN 0103-78110*

Documentos 56

Classificação Digital de Imagens de Sensoriamento Remoto: Tutorial Básico

Carlos Fernando Quartaroli
Mateus Batistella

Embrapa Monitoramento por Satélite. Documentos, 56
Área de Comunicação e Negócios (ACN)

Exemplares desta publicação podem ser solicitados à:

Embrapa Monitoramento por Satélite

Av. Dr. Júlio Soares de Arruda, 803 – Parque São Quirino

13088-300, Campinas (SP) – BRASIL

Caixa Postal 491, CEP 13001-970

Telefone: (19) 3256-6030 Fax: (19) 3254-1100

sac@cnpm.embrapa.br

http://www.cnpm.embrapa.br

Comitê de Publicações da Unidade

Presidente: *José Roberto Miranda*

Secretária: *Shirley Soares da Silva*

Membros: *Adriana Vieira de Camargo de Moraes, André Luiz dos Santos Furtado, Carlos Alberto de Carvalho; Carlos Fernando Quartaroli, Cristina Aparecida Gonçalves Rodrigues, Graziella Galinari, Gustavo Souza Valladares, Mateus Batistella*

1ª edição

1ª impressão (2006): 50 exemplares

Todos os direitos reservados.

A reprodução não autorizada desta publicação, no todo ou em parte, constitui violação dos direitos autorais (Lei nº 9.610).

Quartaroli, Carlos Fernando

Classificação Digital de Imagens de Sensoriamento Remoto: Tutorial Básico / Carlos Fernando Quartaroli e Mateus Batistella – Campinas: Embrapa Monitoramento por Satélite, 2006.

50 p. : il. (Embrapa Monitoramento por Satélite. Documentos, 56)

ISSN 1806-3322

1. Sensoriamento remoto 2. Processamento de imagens de satélite
3. Imagem Digital I. Batistella, Mateus. II. Embrapa. Centro Nacional de Pesquisa de Monitoramento por Satélite (Campinas, SP). III. Título. IV. Série.

CDD 621.3678

© Embrapa Monitoramento por Satélite, dez. 2006

Sumário

INTRODUÇÃO.....	9
CLASSIFICAÇÃO NÃO SUPERVISIONADA	12
PROCESSAMENTO DA CLASSIFICAÇÃO	12
FILTRAGEM PÓS-CLASSIFICAÇÃO.....	15
IDENTIFICAÇÃO DAS CLASSES	16
CLASSIFICAÇÃO SUPERVISIONADA	17
COLETA DE ASSINATURAS	17
AVALIAÇÃO DA SEPARABILIDADE DAS ASSINATURAS	27
PROCESSAMENTO DA CLASSIFICAÇÃO	33
AVALIAÇÃO DA ACURÁCIA DA CLASSIFICAÇÃO.....	34
INTERPRETAÇÃO DA MATRIZ DE ERROS.....	45
CÁLCULO E INTERPRETAÇÃO DA ESTATÍSTICA KAPPA	46
CONSIDERAÇÕES FINAIS	49
REFERÊNCIAS.....	50

Figuras

Figura 1 – Ícone e menu do ERDAS IMAGINE que permite acesso às ferramentas de classificação.....	12
Figura 2 – Quadros que permitem escolher a imagem de entrada e saída para a classificação não supervisionada e o esquema de cores para a representação das classes que serão geradas.	13
Figura 3 – Imagem resultante da classificação não supervisionada.	13
Figura 4 –Quadro que permite editar as cores de visualização de cada classe.	14
Figura 5 –Imagem classificada com o novo padrão de cores para as classes.....	14
Figura 6 – Imagem classificada após a aplicação do filtro Majority. A figura à esquerda resultou da aplicação do filtro com janela de tamanho 5 X 5 pixels. Na obtenção da figura à direita, aplicou-se o filtro com janela de 7 X 7 pixels.	15
Figura 7 – Quadro de edição dos atributos. A coluna com o nome das classes (seta vermelha) pode ser editada.	16
Figura 8 – Bloco de notas com as coordenadas dos pontos de referência para a delimitação das amostras de treinamento.....	18
Figura 9 – Opções para salvar o arquivo de coordenadas das amostras de treinamento com extensão dat.	18
Figura 10 – Quadro "Vector Utilities" com a opção de transformar um arquivo de texto ASCII em pontos (ASCII to Point Vector Layer).....	19
Figura 11 – Quadro usado para importar um arquivo ASCII e convertê-lo para um arquivo vetorial de pontos.	19
Figura 12 – Quadro com as opções de importação de arquivos em ASCII.....	20
Figura 13 – Parte da imagem rec_landsat.img com os pontos de referência para a delimitação de amostras de treinamento.	20
Figura 14 – Editor de assinaturas do ERDAS IMAGINE.....	21
Figura 15 – Editor de assinaturas mostrando algumas amostras já coletadas. O nome e a cor das três primeiras assinaturas já foram alterados.	22
Figura 17 – Quadro usado para alterar as propriedades da ferramenta " Crescimento de região"	23
Figura 18 – Opções da ferramenta Crescimento de Região	24
Figura 19 – Paleta de ferramentas AOI. No destaque, a ferramenta crescimento de região	25
Figura 20 – AOI desenhada pela ferramenta "crescimento de região".	26

Figura 21 – Quadro utilizado para salvar as assinaturas coletadas (arquivo*.sig)	26
Figura 22 – Editor de assinaturas com uma assinatura selecionada (em amarelo). Ao clicar com o botão direito do mouse sobre a assinatura selecionada, um menu é aberto permitindo apagar uma amostra selecionada (Delete Selection) entre outras opções.	27
Figura 23 – Quadro que permite escolher o método que será usado para avaliar a separabilidade das assinaturas.	28
Figura 24 – Exemplo de uma matriz de separabilidade das assinaturas. Distâncias calculadas pelo método da divergência transformada.	28
Figura 25 - Histogramas de duas assinaturas exibidos simultaneamente. Os histogramas para a banda 8 (à esquerda) possuem grande área de sobreposição, o que indica uma má separabilidade dessas assinaturas na banda 8. O mesmo não ocorre com os histogramas das mesmas assinaturas para a banda 3 (à direita).	29
Figura 26 – Quadro com as opções para plotagem de histogramas	30
Figura 27 – Histogramas de uma assinatura obtidos para oito bandas de uma imagem Landsat.....	30
Figura 28 – Histograma mostrando uma distribuição da resposta espectral bimodal.....	31
Figura 29 - Plotagem do valor médio dos pixels que compõem as amostras de treinamento para cada uma das bandas de uma imagem com 8 bandas.....	31
Figura 30 – Seleção das bandas que serão utilizadas no processo de classificação.	32
Figura 31 – Quadro que permite atribuir um nome para a imagem classificada e definir as regras de decisão da classificação supervisionada.	33
Figura 32 - Raster Attribute Editor. Anote o número atribuído para cada classe da imagem resultante da classificação (coluna Row).	34
Figura 33- Quadro usado para a avaliação da acurácia (Accuracy Assessment).	35
Figura 34 – Instrução para selecionar o visor onde a imagem classificada está aberta.....	35
Figura 35 – Quadro usado para alterar as cores dos pontos que serão usados no processo de avaliação da acurácia	35
.Figura 36 – Seleção dos parâmetros da distribuição dos pontos aleatórios.	36
Figura 37 - Quadro Accuracy Assessment com as coordenadas dos pontos aleatórios gerados (colunas X e Y).....	37
Figura 38 – Imagem com os pontos aleatórios gerados para o processo de verificação da acurácia.....	38
Figura 39 – Mapa de uso e cobertura das terras sobreposto à imagem classificada. Em destaque, o ponto aleatório #2, identificado no mapa de uso e cobertura como Floresta estacional semidecidual.	38
Figura 40 – Tabela de atributos do mapa de uso e cobertura das terras mostrando, em amarelo, o registro do polígono selecionado na figura anterior	39

Figura 41 – Quadro Accuracy Assessment com as classes verificadas na imagem classificada (coluna Class) e as classes verificadas no mapa de referência (ou verdade de campo) para os pontos aleatórios utilizados na avaliação da acurácia da classificação.....	41
Figura 42 – Relatório de acurácia com a matriz de erros e os valores da estatística kappa.....	42
Figura 43 – Relatório de acurácia, com o número de pontos de referência selecionados (Reference Totals), classificados (Classified Totals) e classificados corretamente (Number Correct) para cada classe, além das acurácias do produtor (Producers Accuracy) e do usuário (Users Accuracy) para cada classe e da acurácia geral (Overall Classification Accuracy).....	43
Figura 44 – Trecho do relatório dos pontos aleatórios. Os pontos aleatórios gerados correspondem a uma célula de 9 pixels (3X3 pixels). Alguns pontos podem conter pixels de mais de uma classe. Nesse caso, é atribuído ao ponto, o valor da classe majoritária da célula. A célula 14, por exemplo, contém cinco pixels da classe 1 e quatro da classe 6, portanto, o ponto é considerado como pertencente à classe 1.....	44

Tabelas

Tabela 1 – Coordenadas dos pontos de referência para a delimitação das amostras de treinamento.....	17
Tabela 2 – Ficha para anotação das classes de uso e cobertura observadas nos pontos aleatórios gerados para a avaliação da acurácia da classificação.	40
Tabela 3 – Exemplo de uma matriz de erros.	45
Tabela 4 – Cálculo dos valores de acurácia para os dados da matriz de erros apresentada na Tabela 3.	46

Apresentação

Este tutorial apresenta conceitos básicos sobre classificação digital de imagens de Sensoriamento Remoto e propõe exercícios de classificação que exploram as principais funcionalidades do software Erdas Imagine.

Destina-se ao treinamento de estudantes e profissionais iniciantes nas técnicas de classificação digital de imagens de Sensoriamento Remoto. Recomenda-se aos interessados que não conheçam as técnicas básicas de processamento de imagens, ou que não tenham prática no uso do software Erdas Imagine, que executem anteriormente o tutorial básico, publicado pelos mesmos autores com o título "**Processamento de Imagens de Sensoriamento Remoto: tutorial básico**".

Algumas técnicas utilizadas neste tutorial exigem, para um melhor entendimento, o conhecimento de conceitos avançados de Matemática, Estatística e Processamento de Imagens e podem necessitar do acompanhamento de um instrutor para esclarecer esses conceitos aos leitores que desejem executar o tutorial.

Evaristo Eduardo de Miranda

Chefe-Geral

Embrapa Monitoramento por Satélite

Classificação Digital de Imagens de Sensoriamento Remoto: Tutorial Básico

Carlos Fernando Quartaroli

Mateus Batistella

Introdução

Classificação é um dos processos utilizados para a extração de informação em imagens. Por meio desse processo, os pixels de uma imagem são agrupados em classes ou temas. Dependendo do tipo de informação que se quer extrair dos dados originais, as classes podem estar associadas a feições conhecidas da superfície ou podem simplesmente representar áreas que parecem diferentes para o computador (ERDAS, 1999).

É muito comum o uso das técnicas de classificação de imagens para o mapeamento da cobertura das terras. Nesses mapeamentos, as classes estão normalmente associadas a diferentes formas de cobertura das terras como florestas, pastagens, áreas urbanas, corpos d'água, culturas agrícolas, etc..

O processo de classificação pode ocorrer por pixel ou por regiões. Na classificação por pixel, o algoritmo classificador utiliza a informação espectral de cada pixel isolado para achar regiões homogêneas (INPE, 2005). Por outro lado, os classificadores por regiões utilizam a informação espectral de cada pixel da imagem e a informação espacial que envolve a relação entre o pixel e seus vizinhos, procurando reconhecer áreas homogêneas nos dados orbitais, baseados nas propriedades espectrais e espaciais dessas áreas na imagem (MOREIRA, 2001).

O processo de classificação também pode ser supervisionado ou não supervisionado. A classificação não supervisionada é um método computacional automático de agrupamento (ERDAS, 1999). Os algoritmos de classificação não supervisionada não utilizam dados de treinamento como base para a classificação. Os pixels são examinados e agregados em classes com base nos agrupamentos naturais presentes nos valores da imagem. A premissa básica é que os valores correspondentes a um certo tipo de cobertura encontram-se próximos enquanto valores de diferentes classes devam estar comparativamente bem separados no espaço de atributos¹ da imagem (LILLESAND et al. 2004).

¹ Espaço de atributos (*feature space*) de uma imagem, também chamado de *scatterplot* é um gráfico dos valores (DN) de uma banda da imagem plotados contra os valores de uma outra banda. O espaço de atributos de uma assinatura é uma área delimitada dentro do espaço de atributos de uma imagem, ao redor dos valores correspondentes ao conjunto de treinamento dessa assinatura.

Na classificação supervisionada, o usuário inicialmente aponta um conjunto de amostras de treinamento para cada classe que deseja diferenciar na imagem (INPE, 2005). As amostras de treinamento são áreas delimitadas sobre a imagem que correspondem a locais no terreno representativos de cada classe. Para definir as classes que serão mapeadas e as áreas utilizadas como amostras de treinamento é preciso que o analista tenha um conhecimento prévio da área representada na imagem. Esse conhecimento pode ser teórico (conhecimento do comportamento espectral dos alvos) ou prático (adquirido em visitas ao campo, em mapas, por meio de fotografias aéreas ou imagens de alta resolução) (RICHARDS, 1986; NOVO, 1992).

A partir das amostras de treinamento são estabelecidas assinaturas espectrais para cada classe que se deseja diferenciar na imagem. Antes da classificação dos dados é conveniente avaliar a separabilidade das assinaturas. A separabilidade é uma medida estatística da distância espectral entre duas assinaturas (ERDAS, 1999). Se a distância espectral entre duas amostras não é significativa, o algoritmo de classificação pode não conseguir fazer uma boa distinção entre as duas classes que elas representam. Quando detectadas assinaturas de classes diferentes com má separabilidade pode ser necessário rever as áreas de treinamento, eliminar do processo de classificação as bandas nas quais as assinaturas mostram-se próximas, ou mesmo, estudar a possibilidade de fusão das assinaturas e o agrupamento das classes que elas representam em uma única classe.

Após a criação e a avaliação do conjunto de assinaturas, o próximo passo é fazer a classificação dos dados. Cada pixel é analisado independentemente. O vetor composto pelos valores de cada pixel é comparado com cada assinatura, de acordo com o algoritmo ou regra de decisão adotado. Pixels que passam pelo critério estabelecido pela regra de decisão são designados para uma das classes. O ERDAS IMAGINE permite que o usuário escolha tanto métodos paramétricos como não paramétricos no processo de classificação.

Os métodos paramétricos são baseados em parâmetros estatísticos (matriz de covariância e vetor de médias, por exemplo) dos pixels que compõem a assinatura (ERDAS, 1999). O método paramétrico mais utilizado é o da Máxima Verossimilhança. Esse método considera que a nuvem de pontos que formam as amostras de treinamento é normalmente distribuída. Sob essa hipótese, a distribuição do padrão de resposta da classe pode ser completamente descrita pelo vetor de médias e pela matriz de covariância. Por meio desses parâmetros, calcula-se a probabilidade estatística de um certo pixel pertencer a cada uma das classes que se pretende discriminar na imagem (LILLESAND et al. 2004). A classe que apresentar o maior valor de probabilidade será assinalada para o pixel em questão, ou então, o pixel será classificado como desconhecido se os valores de probabilidade calculados forem inferiores a um limiar definido pelo analista.

Os métodos não paramétricos não utilizam estatísticas na classificação dos pixels. Se um pixel está localizado dentro das fronteiras de uma assinatura não paramétrica, então o algoritmo assinala o pixel para a classe associada a essa assinatura. As assinaturas não paramétricas são definidas por objetos discretos (polígonos ou retângulos) delimitados no espaço de atributos da imagem a partir da disposição do conjunto de treinamento de cada classe. O ERDAS IMAGINE dispõe de dois algoritmos de classificação que utilizam métodos não paramétricos: o do espaço de atributos (feature space) e o do paralelepípedo (ERDAS, 1999). O método do espaço de atributos simplesmente determina se o pixel está ou não dentro da área delimitada pelo espaço de atributos de uma determinada assinatura. Caso positivo, o pixel é designado para a classe que a assinatura representa.

O método do paralelepípedo também utiliza áreas delimitadas no espaço de atributos da imagem a partir dos valores dos conjuntos de treinamento definidos para cada classe. Essas áreas têm a forma de retângulos (para um espaço bi-dimensional) ou de paralelepípedos (para espaços com dimensão maior que 2). As arestas do paralelepípedo que será usado para uma determinada classe são definidas pelo valores (DN) máximos e mínimos do conjunto de treinamento dessa classe. Todos os pixels com valores situados dentro de um dos paralelepípedos (ou retângulos) serão classificados para a classe relacionada a esse paralelepípedo (ERDAS, 1999). Tanto o método

do paralelepípedo, quanto o método do espaço de atributos exigem regras adicionais para definir o que deverá ocorrer com os pixels cujos valores não se situarem dentro de nenhum espaço de atributos ou paralelepípedo, bem como para aqueles que se situarem em áreas de sobreposição dos espaços de atributos ou paralelepípedos.

A classificação não supervisionada é um método computacional automático de agrupamento (ERDAS, 1999) Os algoritmos de classificação não supervisionada não utilizam dados de treinamento como base para a classificação. Os pixels são examinados e agregados em classes com base nos agrupamentos naturais presentes nos valores da imagem. A premissa básica é que os valores correspondentes a um certo tipo de cobertura encontram-se próximos enquanto valores de diferentes classes devam estar comparativamente bem separados no espaço de atributos da imagem (LILLESAND et al. 2004).

As classes resultantes da classificação não supervisionada são simplesmente agrupamentos de pixels com características espectrais similares (ERDAS, 1999). A priori não estão associadas a nenhum tipo de cobertura ou feição do terreno. O método é geralmente usado quando o conhecimento sobre os dados é pequeno antes da classificação. É então, responsabilidade do analista, depois da classificação, designar um significado para cada classe resultante (JENSEN, 1996).

Classificação não supervisionada

Processamento da classificação

1. Clique sobre o ícone Classifier do painel de ícones do ERDAS IMAGINE.
2. No menu Classification, selecione Unsupervised Classification (Figura 1).

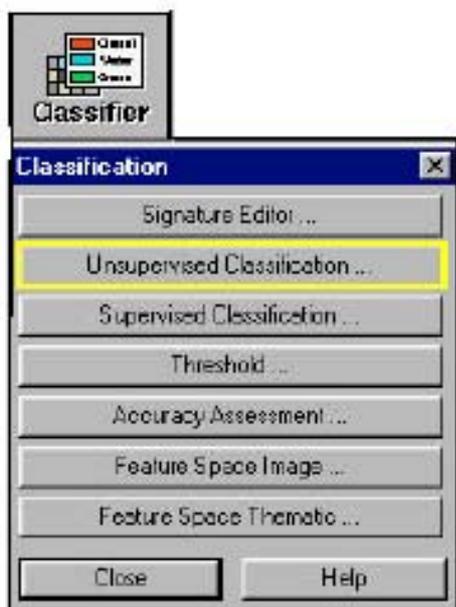


Figura 1 – Ícone e menu do ERDAS IMAGINE que permite acesso às ferramentas de classificação.

3. Clique Close no menu Classification (Figura 1).
4. No quadro Unsupervised Classification (Figura 2), sob Input Raster File, escolha a imagem que será classificada. Sob Output Cluster Layer escolha um nome para a imagem classificada e a pasta onde você deseja salvá-la. Para este exercício usaremos a imagem rec_landsat.img que está na pasta C:/Tutorial_Imagine/Dados. Veja sugestões de nomes para a imagem de saída e para o arquivo de assinaturas na Figura 2. Preencha os demais dados do quadro Unsupervised Classification conforme a Figura 2.
5. O ERDAS IMAGINE cria automaticamente um arquivo de assinaturas para cada classe que ele gera durante a classificação não supervisionada. Este arquivo contém agrupamentos de pixels representativos de cada classe gerada e poderá ser usado posteriormente como amostras de treinamento em uma classificação supervisionada. Para que o ERDAS IMAGINE gere este arquivo, a opção Output Signature Set deverá estar marcada no quadro Unsupervised Classification.
6. Ainda no quadro Unsupervised Classification, clique em Color Scheme Options. O quadro Output Color Scheme Options será aberto (Figura 2). Nesse quadro, marque as mesmas opções da Figura 2 e clique em Close.

7. No quadro Unsupervised Classification, clique em OK. Quando a classificação estiver completa, o quadro Job Status indicará 100 %. Então, clique em OK.

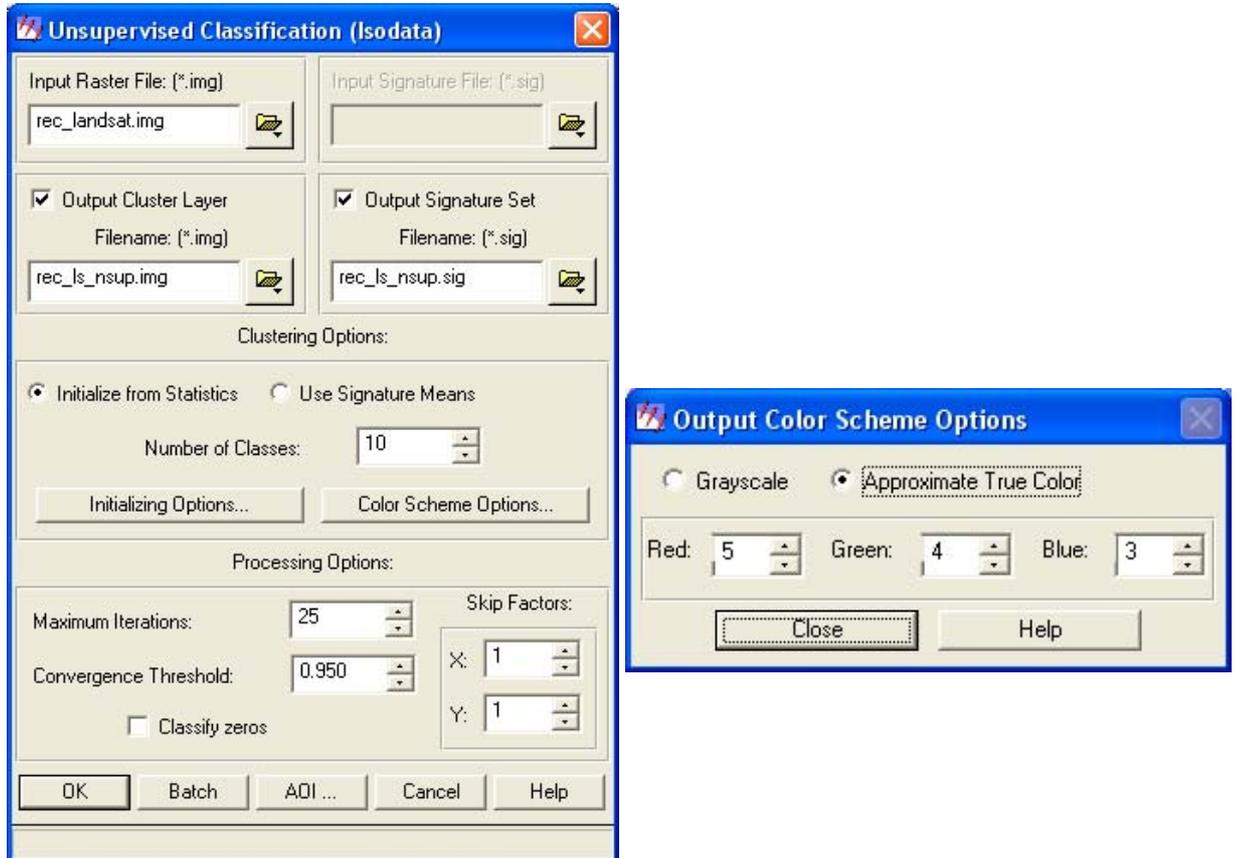


Figura 2 – Quadros que permitem escolher a imagem de entrada e saída para a classificação não supervisionada e o esquema de cores para a representação das classes que serão geradas.

8. Abra a imagem classificada (rec_ls_nsup.img) em um visor (Viewer) (Figura 3).

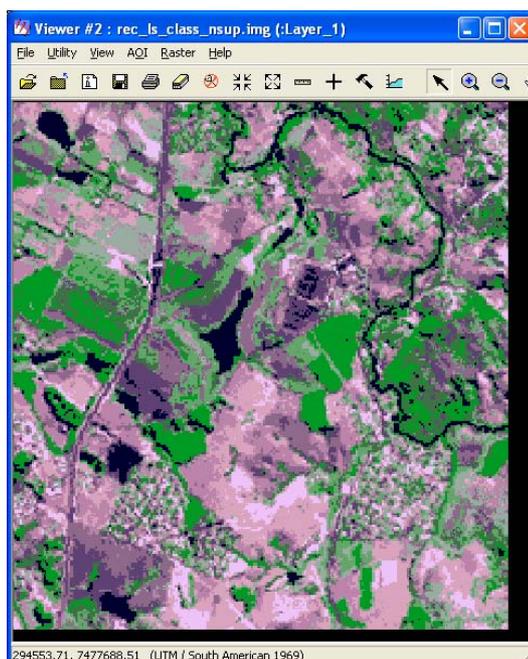


Figura 3 – Imagem resultante da classificação não supervisionada.

9. No menu Raster do visor (Viewer), selecione Attributes. O quadro Raster Attribute Editor será aberto (Figura 4). Para alterar as cores atribuídas a cada classe, clique com o botão direito do mouse sobre a cor que você quer alterar na coluna Color do Raster Attribute Editor e escolha uma nova cor no menu aberto. As alterações de cores na imagem classificada são imediatas (Figura 5).

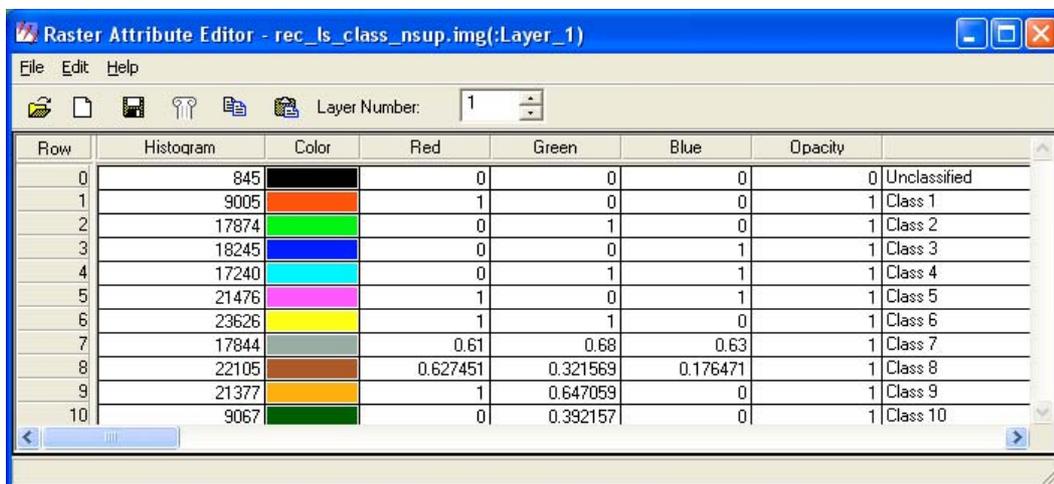


Figura 4 –Quadro que permite editar as cores de visualização de cada classe.

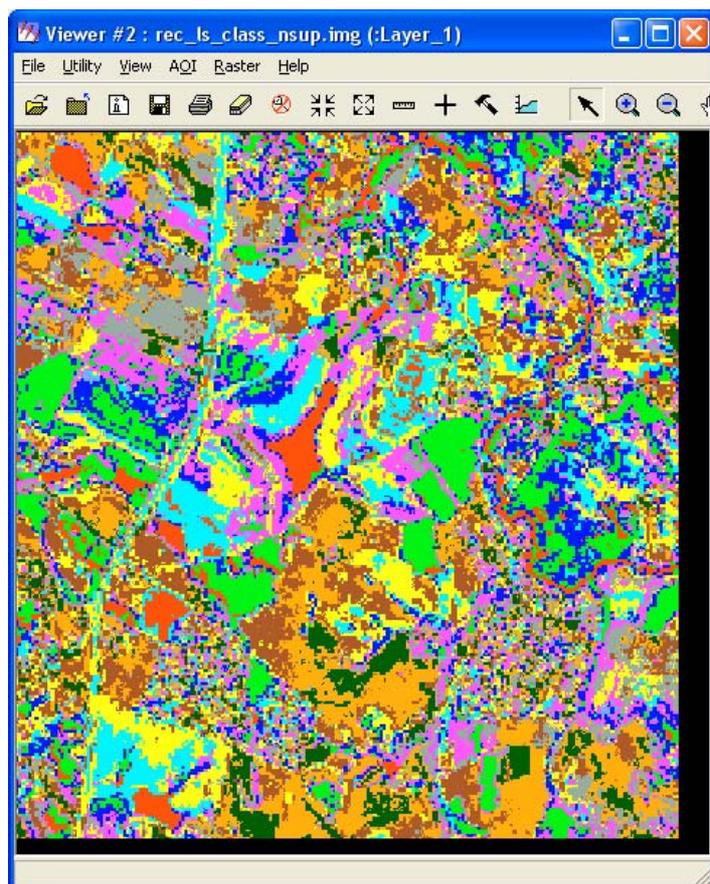


Figura 5 –Imagem classificada com o novo padrão de cores para as classes.

Filtragem pós-classificação

Muitas vezes o resultado da classificação é uma imagem com ruído, representado por pixels isolados, ou pequenos grupos de pixels, assinalados a diversas classes, que ocorrem próximos a áreas homogêneas classificadas. Se existem suspeitas de que áreas isoladas desse tipo, com um número de pixels abaixo de um certo limite, representam erros de classificação, então é possível apagá-los ou absorvê-los em outras áreas adjacentes maiores, pertencentes a outras classes (CROSTA, 1993). Uma das técnicas utilizadas para a homogeneização de classes em uma imagem classificada é a aplicação do filtro Majority. Esse filtro opera por meio de uma janela móvel de tamanho definido pelo usuário (3x3 pixels, 5X5 pixels, 7x7 pixels, etc.) que percorre toda a imagem classificada. O pixel central da janela assume o valor da classe majoritária verificada entre os pixels que se encontram dentro da janela. Se não há classe majoritária na janela, a identidade do pixel central não é alterada (LILLESAND et al, 2004).

Janelas de maior tamanho para o filtro possibilitam uma maior homogeneização das classes, entretanto, qualquer aplicação do filtro Majority deve ser feita com critério, pois pode-se estar desprezando áreas corretamente classificadas.

10. No menu do visor que exibe a imagem classificada (rec_ls_class_nsup.img) clique na opção Raster e selecione Filtering | Statistical Filtering. No quadro Focal Function, escolha a função Majority e Window Size 5 X 5. Clique OK e veja o resultado (Figura 6). Áreas pequenas de uma determinada classe no meio de áreas maiores de outra classe desaparecem, substituídas pela classe dominante na vizinhança. Caso ainda não seja satisfatória a filtragem efetuada para eliminar as áreas muito pequenas, pode-se voltar à imagem original e aumentar o tamanho da janela para 7X7, por exemplo (Figura 6).

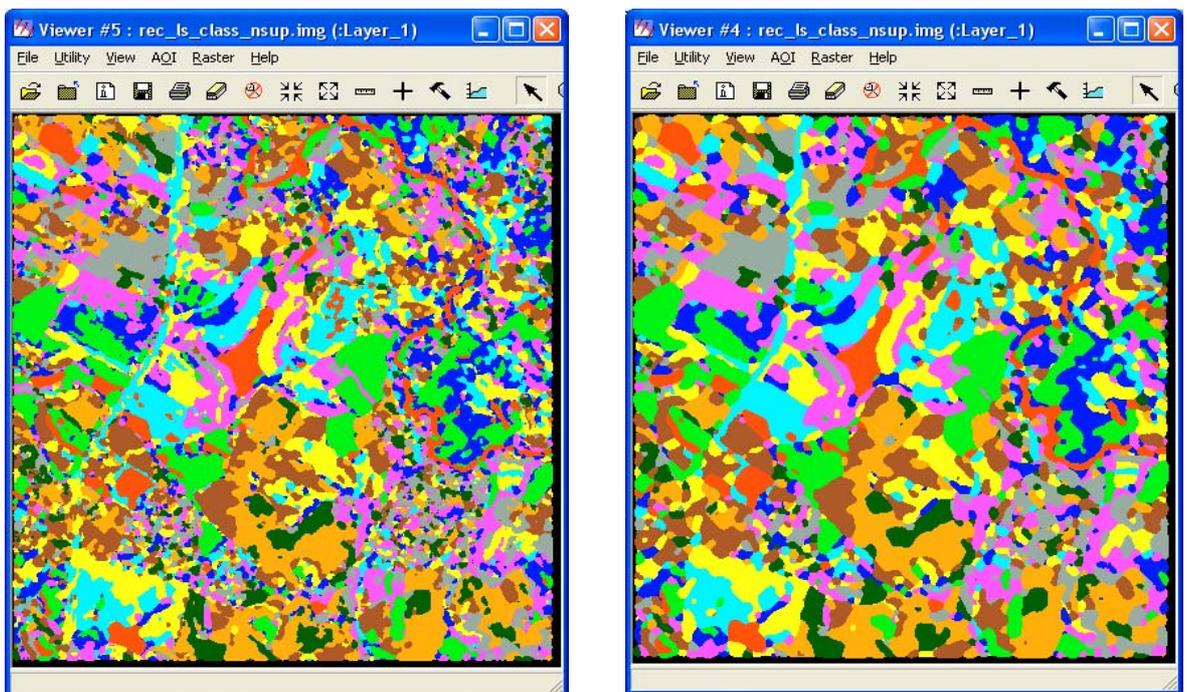


Figura 6 – Imagem classificada após a aplicação do filtro Majority. A figura à esquerda resultou da aplicação do filtro com janela de tamanho 5 X 5 pixels. Na obtenção da figura à direita, aplicou-se o filtro com janela de 7 X 7 pixels.

11. Para salvar a imagem classificada e filtrada clique em File no menu do visor onde a imagem está aberta e escolha Save | Top Layer as... Escolha um nome e pasta para a imagem.

Identificação das classes

12. No quadro Raster Attribute Editor, coluna Class Names, observe que o ERDAS IMAGINE apenas atribui números às classes (Class 1, Class 2, etc.). Um interpretador experiente poderá analisar a imagem classificada e atribuir um nome que tenha um significado real para cada classe.

13. Para a imagem que estamos trabalhando, vamos atribuir classes de uso e cobertura das terras. Interprete um possível uso ou cobertura para cada classe da imagem classificada e altere seu nome.

14. Para alterar o nome das classes, clique sobre o nome original no quadro Raster Attribute Editor (Class1, Class2, ...)(Figura 7, seta vermelha). Apague este nome, digite o novo nome seguido de ENTER. Eventualmente, alguns pixels da imagem poderão não ser classificados e permanecerão como unclassified (não classificados).

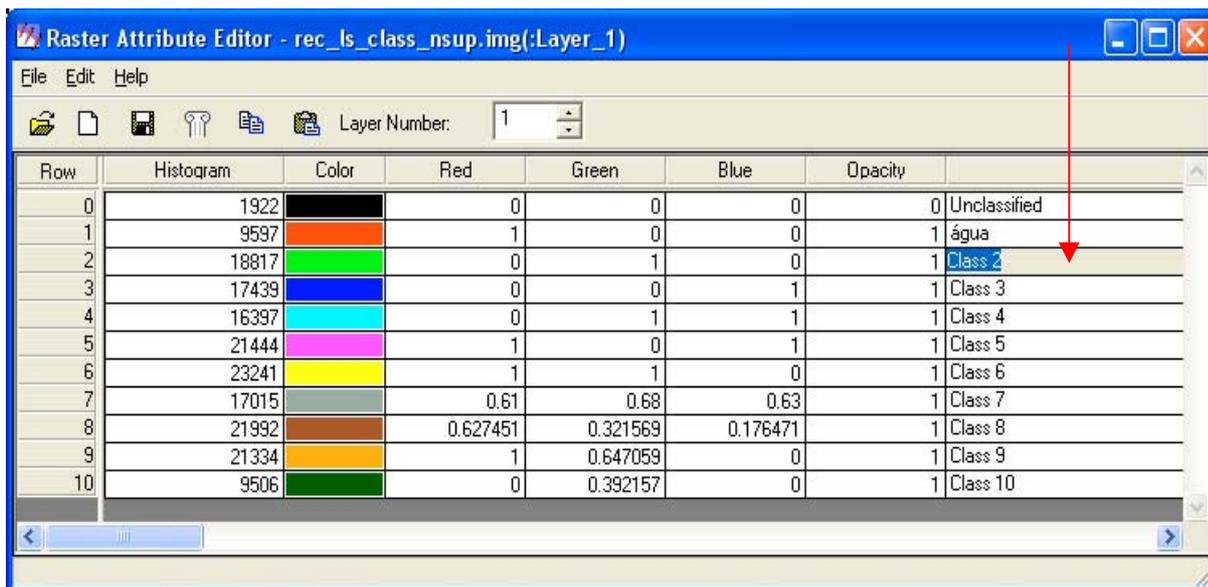


Figura 7 – Quadro de edição dos atributos. A coluna com o nome das classes (seta vermelha) pode ser editada.

Classificação supervisionada

Coleta de Assinaturas

1. Clique Viewer na barra de ícones do ERDAS IMAGINE e selecione File | Open | Raster Layer. O quadro Select Layer to Add será aberto.
2. Abra o arquivo rec_landsat.img. Escolha uma composição colorida R=4, G=5 e B=3 ou outra que você ache conveniente.
3. Inicialmente, você deverá definir um conjunto de amostras de treinamento para cada classe de cobertura presente na imagem. Essas amostras são pequenas áreas delimitadas sobre a imagem que correspondem a locais no terreno representativos de cada classe. Para definir as classes que serão mapeadas e as áreas utilizadas como amostras de treinamento é preciso que o analista tenha um conhecimento prévio da área representada na imagem. Esse conhecimento pode ser teórico (conhecimento do comportamento espectral dos alvos) ou prático (adquirido em visitas ao campo, em mapas, por meio de fotografias aéreas ou imagens de alta resolução) (RICHARDS, 1986; NOVO,1992).
4. Para este tutorial foi executado um trabalho prévio de conhecimento da área coberta pela imagem rec_landsat.img, com visitas ao campo e a anotação das coordenadas UTM de pontos que podem servir como base para a delimitação das amostras de treinamento. As classes detectadas durante essa visita e as coordenadas desses pontos são apresentadas na Tabela 1.

Tabela 1 – Coordenadas dos pontos de referência para a delimitação das amostras de treinamento.

Classes	Coordenadas UTM	
Culturas perenes	291.529	7.479.940
Culturas perenes2	291.800	7.480.290
Cana-de-açúcar	292.679	7.480.308
Solo exposto	293.207	7.480.005
Construção	295.205	7.479.938
Pasto limpo	293.234	7.478.008
Pasto limpo2	293.930	7.477.673
Pasto limpo3	296.155	7.477.639
Pasto sujo	291.785	7.477.025
Mata	294.397	7.479.183
Capoeira	292.716	7.478.317
Culturas anuais	291.514	7.478.955
Eucalípto	291.417	7.478.649
Água	293.191	7.479.541
Áreas urbanas	295.267	7.477.655

5. Para facilitar a delimitação das amostras de treinamento é conveniente que você visualize os pontos da Tabela 1 sobre a imagem. Esses pontos poderão ser substituídos por outros, caso você tenha feito um reconhecimento da área por visitas ao campo e coletado as coordenadas de pontos representativos das classes com um aparelho de GPS.

6. Digite as coordenadas da Tabela 1 no Bloco de Notas do Windows. O acesso ao Bloco de Notas normalmente é feito pelo menu Iniciar do Windows, pela escolha da opção Todos os Programas, seguida pela opções Acessórios e Bloco de Notas. Utilize Tab para separar as colunas e Enter no fim das linhas. O arquivo deverá ficar com a aparência da Figura 8. Não utilize pontos ou vírgulas para separar milhares e milhões.

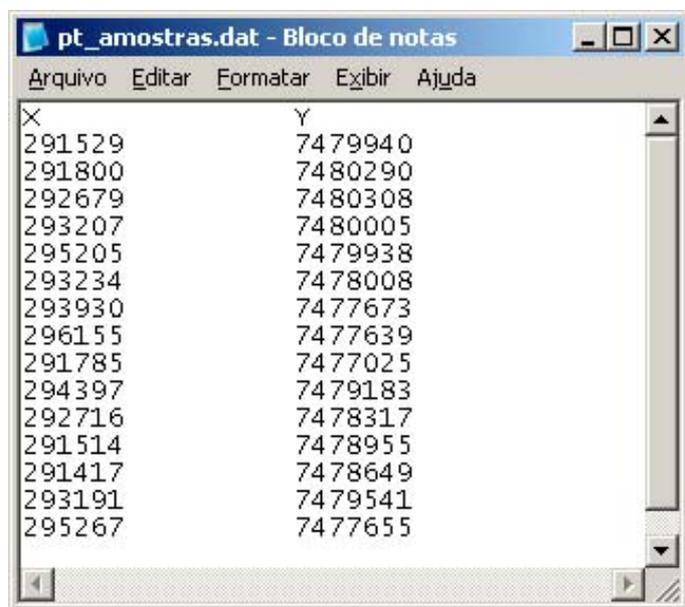


Figura 8 – Bloco de notas com as coordenadas dos pontos de referência para a delimitação das amostras de treinamento.

7. Após a digitação, o arquivo deverá ser salvo com a extensão dat. Observe que o padrão do Bloco de Notas é a extensão txt. Portanto, antes de atribuir um nome ao arquivo, altere a opção "Salvar como tipo" para "Todos os arquivos". Em seguida, digite o nome do arquivo seguido por .dat e clique em Salvar. Veja a Figura 9.



Figura 9 – Opções para salvar o arquivo de coordenadas das amostras de treinamento com extensão dat.

8. Na barra de ícones do ERDAS IMAGINE clique sobre o ícone Vector.
9. No menu Vector Utilities (Figura 10) escolha a opção " ASCII to Point Vector Layer". Por meio do quadro "Import ASCII File to Point Coverage" importe o arquivo *.dat salvo na etapa 7 e escolha um nome e local para o arquivo de saída que assumirá automaticamente a extensão arcinfo (Figura 11). Clique em OK.

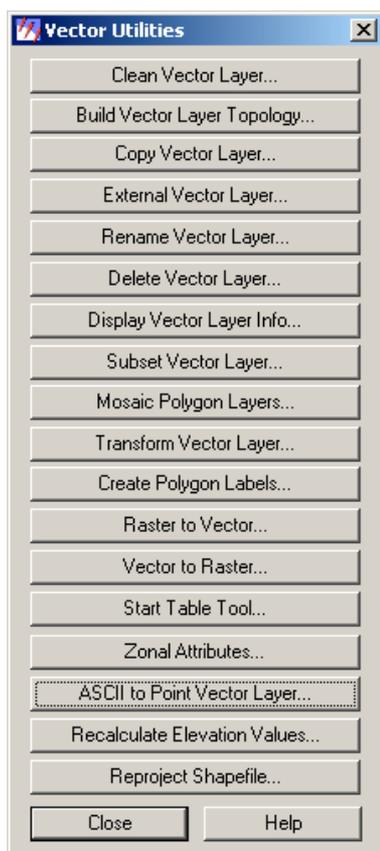


Figura 10 – Quadro "Vector Utilities" com a opção de transformar um arquivo de texto ASCII em pontos (ASCII to Point Vector Layer).

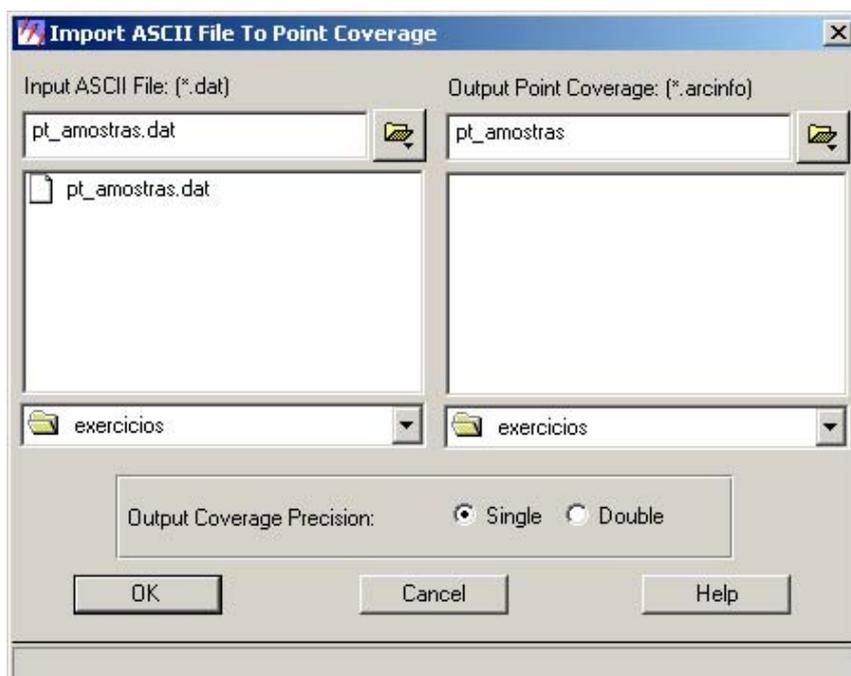


Figura 11 – Quadro usado para importar um arquivo ASCII e convertê-lo para um arquivo vetorial de pontos.

10. O quadro "Import Options" será apresentado. Preencha-o conforme a Figura 12 e clique em OK. Observe que os campos de interesse (X e Y) foram separados por tabulação (Tab). O final de linha foi marcado pelo acionamento da tecla "Return NewLine" (↵) e uma linha deve ser pulada (Number of Rows to Skip) para o acesso ao início dos dados. Essa linha corresponde ao título das colunas: X e Y. A caixa Column mapping mostra o título das colunas e a ordem de entrada de cada coluna.

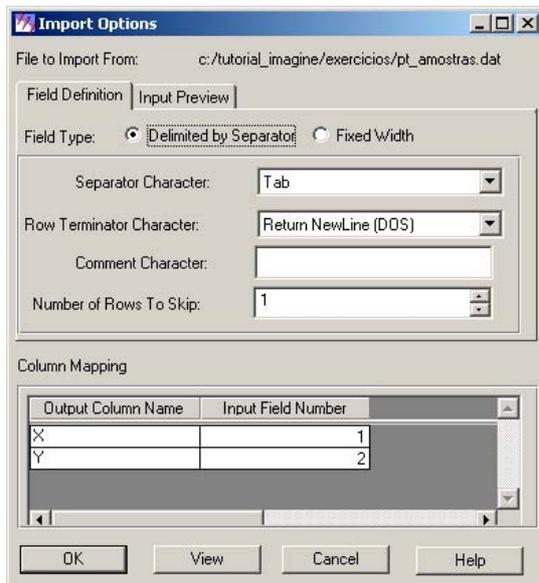


Figura 12 – Quadro com as opções de importação de arquivos em ASCII.

11. No mesmo visor onde está aberta a imagem `rec_landosat.img`, abra o arquivo vetorial de pontos salvo na etapa 9 (extensão `arcinfo`) sobre a imagem.
12. Pode ser necessário alterar as propriedades dos pontos, principalmente seu tamanho, para que eles sejam visíveis na tela. Para alterar essas propriedades acesse o menu `Vector` do visor e selecione `"Viewing Properties"`. Detalhes de como alterar as propriedades de exibição de um arquivo vetorial podem ser encontrados em Quartaroli e Batistella (2005). Parte da imagem com alguns dos pontos é apresentada na Figura 13.

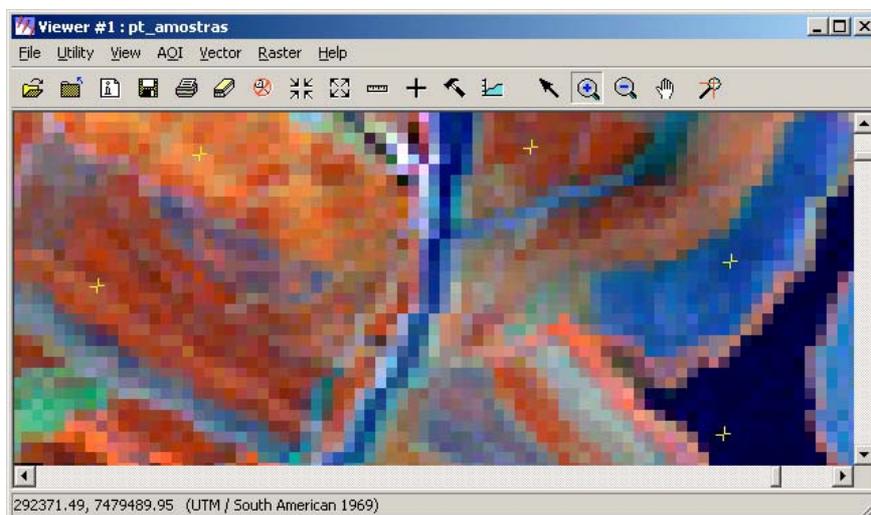


Figura 13 – Parte da imagem `rec_landosat.img` com os pontos de referência para a delimitação de amostras de treinamento.

13. Volte à barra de ícones do ERDAS IMAGINE e clique sobre o ícone Classifier.
14. No menu Classification escolha Signature Editor.
15. O editor de assinaturas (Signature Editor) será aberto (Figura 14).

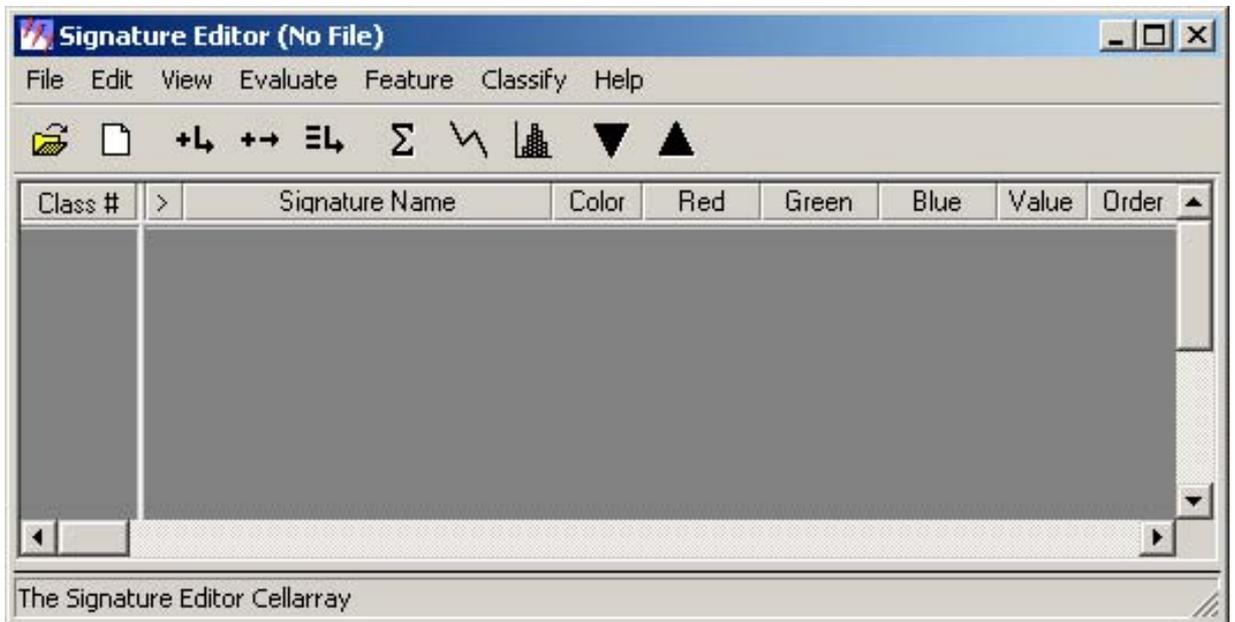


Figura 14 – Editor de assinaturas do ERDAS IMAGINE

16. No visor (Viewer) onde a imagem está sendo exibida, selecione, a partir da barra de menus, as opções AOI | Tools.
17. A paleta AOI é mostrada. Vamos iniciar o processo de coleta de amostras de treinamento. Esse processo consiste na delimitação de pequenas áreas sobre a imagem, representativas das classes de cobertura. Essas áreas são delimitadas pelas ferramentas de AOI (area of interest) do ERDAS IMAGINE (polígonos, elipses, retângulos ou crescimento de regiões). Veja como usar as ferramentas de AOI em "Processamento de Imagens de Sensoriamento Remoto: Tutorial Básico" (QUARTAROLI, BATISTELLA, 2005). Os pontos marcados sobre a imagem servem como referência para a delimitação das amostras. Lembre-se que as coordenadas desses pontos foram determinadas em campo e estão situados em áreas representativas de cada classe de uso e cobertura existente na área. O uso associado a cada ponto é apresentado na Tabela 1. Portanto, delimite as amostras de treinamento ao redor desses pontos. Verifique, pela imagem, se há homogeneidade de padrão dentro de cada amostra. Evite delimitar em uma mesma amostra de treinamento, áreas que possam pertencer a classes diferentes. Por exemplo: se há um rio cortando uma mata e no processo de classificação você quer diferenciar água e mata, evite delimitar amostras de mata próximas ao rio. Pelo mesmo motivo, evite incluir nas amostras de treinamento áreas próximas à fronteira entre tipos diferentes de cobertura. Identifique os pontos pelas suas coordenadas e veja na Tabela 1 qual o uso associado a cada ponto.
18. Uma classe espectral pode conter várias amostras de treinamento. Quando se delimita o conjunto de treinamento de uma determinada classe, deve-se procurar analisar diversos locais dentro da cena. Para uma determinada classe espectral, é melhor definir um conjunto de 20 amostras em locais diferentes contendo 40 pixels do que uma amostra em apenas um local contendo 800 pixels. A dispersão dos locais pela cena aumenta a chance do conjunto de treinamento ser representativo da variação das coberturas presentes na cena (LILLESAND et al, 2004).

19. Para transformar uma amostra de treinamento em assinatura da classe que ela representa, posicione o mouse dentro dos limites da amostra e selecione-a com um clique no botão esquerdo do mouse, ou utilize as ferramentas de seleção da paleta AOI. Em seguida, clique sobre o ícone indicado pela seta vermelha na Figura 15, presente no quadro Signature Editor. A assinatura é listada no quadro Signature Editor. O ERDAS IMAGINE atribui um nome genérico à assinatura (class 1, class2,...). Você pode alterar esse nome a qualquer momento, clicando sobre ele, apagando-o e digitando um novo nome (Figura 15). É conveniente que esse nome seja o mesmo da classe de uso e cobertura da amostra. **Importante:** O ERDAS IMAGINE não aceita duas assinaturas com o mesmo nome. Se você, por exemplo, tem duas assinaturas de mata e deseja dar esse nome às amostras, nomeie uma como mata1 e outra como mata2.



Figura 15 – Editor de assinaturas mostrando algumas amostras já coletadas. O nome e a cor das três primeiras assinaturas já foram alterados.

20. Quando há várias amostras de treinamento para uma mesma classe espectral, essas amostras devem ser inseridas no quadro Signature Editor separadamente e com nomes diferentes. O Erdas Imagine trata elas inicialmente como se fossem de classes diferentes. A qualquer momento, pode-se agrupar essas amostras em uma única assinatura para a classe que ela representa. Para agrupá-las selecione as linhas das amostras no quadro Signature Editor. Na barra de menus do mesmo quadro, clique sobre Edit e escolha a opção Merge. Uma nova assinatura é criada com um nome genérico editável. As assinaturas referentes as amostras utilizadas para o agrupamento ainda permanecem no quadro e podem ser excluídas.
21. Caso queira substituir uma assinatura já existente, selecione a linha dessa assinatura no quadro Signature Editor com um clique na célula da coluna Class #. A linha selecionada ficará destacada em amarelo. Em seguida selecione a amostra de treinamento que será usada para a nova assinatura e clique sobre o ícone indicado pela seta verde na Figura 15. A nova assinatura assumirá automaticamente o lugar da anterior.
22. No quadro Signature Editor, você também pode alterar a cor atribuída automaticamente às amostras (Figura 15, seta amarela). Clique com o botão direito do mouse sobre a cor escolhida pelo ERDAS IMAGINE para a assinatura e escolha uma nova no menu. Escolha cores contrastantes para cada amostra. Esse procedimento facilitará a visualização das classes após a classificação.
23. O quadro Signature Editor fornece importantes informações sobre as assinaturas criadas. Veja o significado dessas informações:
- Class #: número arbitrário atribuído à assinatura;
 - >: identifica a assinatura corrente;

- Color: cor que será usada na imagem classificada para representar a classe que a assinatura representa. Para alterar uma cor, clique com o botão direito sobre ela e escolha uma nova cor no menu aberto;
 - Red, Green e Blue: valores dos componentes da cor que representa a assinatura;
 - Value: valor da classe que a assinatura representa. Não coincide necessariamente com o "Class #";
 - Order: ordem para processar a assinatura quando o processo usado depende dessa ordem. Pode ser editado;
 - Count: número de pixels da amostra. A coluna permanece vazia para assinaturas não paramétricas;
 - Prob.: probabilidade (a priori) ou peso para a assinatura que será usada em funções como a máxima verossimilhança e a separabilidade;
 - P: identifica se a assinatura é paramétrica (se o vetor média e a matriz de covariância existem);
 - I: identifica se a matriz de covariância pode ser invertida. Essa condição é necessária para funções como a máxima verossimilhança e a divergência;
 - H: identifica se existem histogramas para a assinatura;
 - A: identifica se a assinatura está associada com uma área de interesse da imagem;
 - FS: identifica se a assinatura foi criada a partir de um espaço de atributos da imagem e o par de camadas utilizado para esse espaço de atributos.
25. A ferramenta "crescimento de região", presente na paleta de ferramentas AOI, pode também ser usada para a aquisição de assinaturas. Essa ferramenta determina quais pixels possuem valores similares a um determinado pixel chamado de "semente". O pixel "semente" é escolhido pelo usuário e deverá ser representativo da classe a qual se quer obter uma amostra de treinamento. Ao pixel "semente", o ERDAS IMAGINE agrega os pixels contíguos com valores similares, seguindo regras de expansão e restrição estabelecidas pelo usuário. O resultado final é a delimitação de uma AOI que poderá ser usada como amostra de treinamento.
26. Antes de implantar o pixel "semente" é necessário estabelecer as propriedades de expansão e restrição da ferramenta "Crescimento de região". No menu do visor, selecione AOI | Seed Properties. O quadro "Region Growing Properties" será aberto (Figura17).

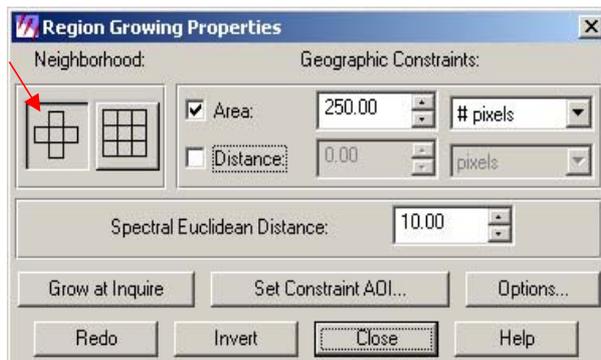


Figura 17 – Quadro usado para alterar as propriedades da ferramenta " Crescimento de região"

27. Escolha como restrição geográfica (Geographic Constraints) a área de 250 pixels. Marque a caixa "Area" e digite 250. Desative a caixa "Distance". Isso fará com que a semente cresça até atingir uma área de 250 pixels, delimitando a área da amostra de treinamento. Observe que também há a opção de restringir o crescimento por uma distância medida a partir do pixel "semente" (opção Distance). Caso prefira, poderá utilizar unidades de medidas de área e comprimento (ha, m) ao invés do número de pixels. Na caixa Espectral Euclidian Distance digite o valor 10. Isso significa que cada pixel selecionado para compor a AOI estará a uma distância euclidiana espectral menor ou igual a 10 unidades de DN (digital number ou nível de cinza) do vetor de médias dos pixels já selecionados para compor a amostra. A distância euclidiana espectral é calculada no espaço n-dimensional, onde n é o número de bandas da imagem.
28. Escolha como restrição geográfica (Geographic Constraints) a área de 250 pixels. Marque a caixa "Area" e digite 250. Desative a caixa "Distance". Isso fará com que a semente cresça até atingir uma área de 250 pixels, delimitando a área da amostra de treinamento. Observe que também há a opção de restringir o crescimento por uma distância medida a partir do pixel "semente" (opção Distance). Caso prefira, poderá utilizar unidades de medidas de área e comprimento (ha, m) ao invés do número de pixels. Na caixa Espectral Euclidian Distance digite o valor 10. Isso significa que cada pixel selecionado para compor a AOI estará a uma distância euclidiana espectral menor ou igual a 10 unidades de DN (digital number ou nível de cinza) do vetor de médias dos pixels já selecionados para compor a amostra. A distância euclidiana espectral é calculada no espaço n-dimensional, onde n é o número de bandas da imagem.
29. Em Neighborhood, clique no ícone da esquerda, indicado por uma seta vermelha na Figura 10. Essa opção permite determinar quais pixels serão considerados contíguos ao pixel semente. Qualquer pixel que satisfaça os critérios de seleção será aceito e tornar-se-á ele próprio um pixel semente, dando prosseguimento ao processo de seleção. Pode-se escolher o esquema de 4 vizinhos (ícone da esquerda) ou o de 8 vizinhos (ícone da direita).
30. Ainda no quadro Region Growing Properties, clique sobre Options... e marque as opções Include Island Polygons e Update Region Mean, presentes no quadro "Region Group Options" (Figura 18). A primeira opção permite ao algoritmo mostrar polígonos ilhas. São áreas dentro da região de crescimento que não concordam com as propriedades da região de crescimento. Quando ativada essa opção, os polígonos ilhas são excluídos dos processos subsequentes usando a AOI (cálculo de área, por exemplo). A segunda opção permite que a média dos níveis de cinza da região de crescimento seja atualizada assim que a região cresce.



Figura 18 – Opções da ferramenta Crescimento de Região

31. Use a ferramenta "crescimento de região" para estabelecer uma amostra para a classe água. A "semente" poderá ser implantada no açude, reconhecido facilmente no centro da imagem. Clique sobre o ícone "crescimento de região" (círculo amarelo, Figura 19) e, em seguida, clique sobre o pixel escolhido como "semente" para representar a classe água. A AOI será desenhada automaticamente (Figura 20). Para incluí-la como amostra de treinamento, basta seguir o mesmo procedimento de inclusão das amostras anteriores (etapa 19).



Figura 19 – Paleta de ferramentas AOI. No destaque, a ferramenta crescimento de região

32. O arquivo de assinaturas pode ser salvo. Clique na opção File no menu do quadro Signature Editor, selecione Save e escolha uma pasta e um nome para o arquivo. (Figura 21). Para abrir um arquivo de assinaturas já salvo, use a opção File | Open do quadro Signature Editor. Os arquivos de assinaturas sempre têm a extensão *.sig.
33. Uma assinatura coletada pode ser apagada. Selecione-a clicando com o botão esquerdo do mouse na sua linha e na coluna Class. Em seguida clique com o botão direito do mouse sobre a linha selecionada e escolha Delete Selection no menu aberto (Figura 22).
34. Escolha as bandas da imagem que vamos utilizar para o processo de classificação. Inicialmente vamos escolher as bandas 1,2,3,4,5 e 7. Após a avaliação da separabilidade de assinaturas, pode ser conveniente excluir algumas dessas bandas do processo de classificação por não apresentarem boa separabilidade para as assinaturas usadas. Clique em Edit no menu do quadro Signature Editor e selecione Layer Selection. Em Layer to Use, selecione as bandas 1,2,3,4,5 e 7. Basta clicar sobre elas com a tecla Shift acionada.
35. Após a introdução de todas as assinaturas, é preciso verificar o número de pixels de cada assinatura (coluna Count do quadro Signature Editor). Os algoritmos que serão utilizados para avaliar a separabilidade (divergência transformada) e para classificar a imagem (máxima verossimilhança), assim como outros algoritmos baseados em estatísticas, exigem assinaturas com um número mínimo de pixels igual ao número de bandas selecionadas da imagem mais um. Contudo, na prática, uma amostra de tamanho maior melhora a representação estatística da classe espectral. Costuma-se usar um mínimo de 10 N a 100 N pixels para compor uma assinatura, onde N é o número de bandas da imagem que será usado no processo de classificação (Lillesand et al., 2004). Portanto, como estamos trabalhando com 6 bandas da imagem Landsat, o número de pixels mínimo de cada assinatura deverá ser 7, mas recomenda-se para cada assinatura um número de pixels entre 60 e 600.
36. Caso tenha alguma assinatura com baixa quantidade de pixels, estude a possibilidade de aumentar seu tamanho por meio do aumento da área das amostras, pelo agrupamento de duas ou mais assinaturas, ou mesmo pela agregação de novas amostras de treinamento à essa assinatura.

37. Verifique, na coluna I do quadro Signature Editor, se a linha correspondente a cada assinatura está assinalada com um X. Isso significa que a matriz de covariância da assinatura pode ser invertida, condição também necessária para usar as funções de divergência e máxima verossimilhança.

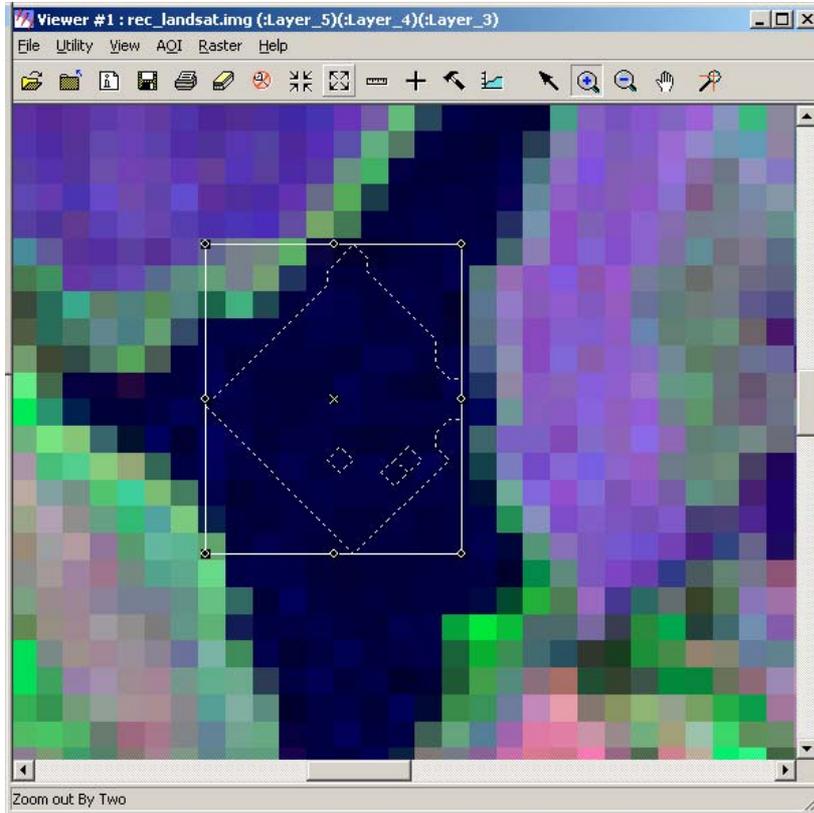


Figura 20 – AOI desenhada pela ferramenta "crescimento de região".

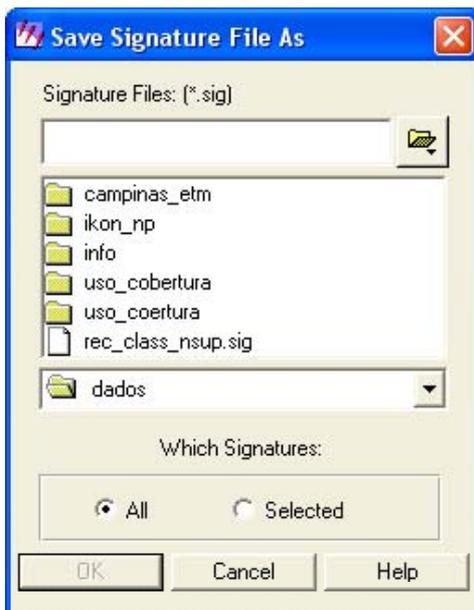


Figura 21 – Quadro utilizado para salvar as assinaturas coletadas (arquivo *.sig)



Figura 22 – Editor de assinaturas com uma assinatura selecionada (em amarelo). Ao clicar com o botão direito do mouse sobre a assinatura selecionada, um menu é aberto permitindo apagar uma amostra selecionada (Delete Selection) entre outras opções.

Avaliação da separabilidade das assinaturas

38. No quadro Signature Editor, clique em Evaluate e selecione Separability.
39. Preencha o quadro aberto conforme Figura 23. Há quatro métodos disponíveis para a avaliação da separabilidade das assinaturas. Usaremos o método da divergência transformada (Transformed Divergence).
40. Clique OK.
41. Um quadro com a matriz de separabilidade semelhante ao da Figura 24 é mostrado
42. Este quadro permite avaliar a separabilidade entre as amostras. Observe que é atribuído um número para cada amostra e este número é colocado no título das linhas e das colunas. Deste modo, a célula da coluna 3 e da linha 2, por exemplo, contém um número que permite avaliar a separabilidade das amostras 3 e 2. Os números da matriz de separabilidade segundo o Método de Divergência Transformada variam de 0 a 2000. Em geral, resultados maiores que 1900 significam que as amostras podem ser bem separadas. Entre 1700 e 1900, a separabilidade é razoável. Abaixo de 1700, a separabilidade é ruim. Logicamente, a diagonal da matriz de separabilidade tem valores sempre iguais a zero.

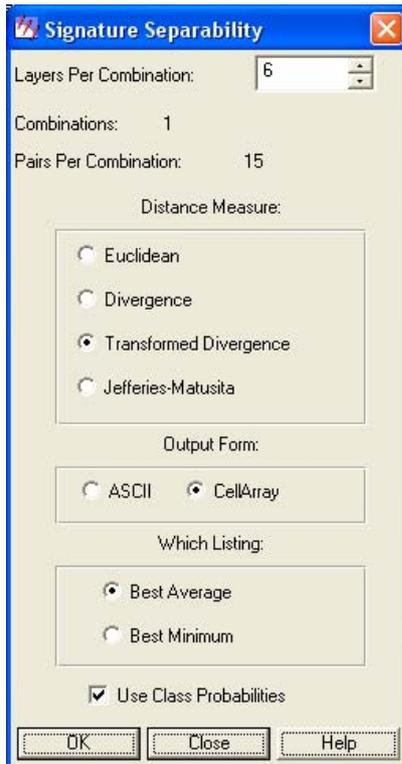


Figura 23 – Quadro que permite escolher o método que será usado para avaliar a separabilidade das assinaturas.

Signature Name	1	2	3	4	5	6
Culturas perenes 1	0	1986.32	2000	1955.37	1938.83	1132.58
Culturas perenes2 2	1986.32	0	2000	2000	32.4501	1427.18
Culturas anuais 3	2000	2000	0	2000	2000	2000
Solo Exposto 4	1955.37	2000	2000	0	1999.98	1998.68
Cana-de-açúcar 5	1938.83	32.4501	2000	1999.98	0	1183.87
Construção 6	1132.58	1427.18	2000	1998.68	1183.87	0
Água 7	2000	2000	2000	2000	2000	2000
Capoeira 8	2000	1618.48	2000	2000	1635.81	1995.06
Eucalipto 9	1999.99	1481.72	2000	2000	1237.13	1988.16
Pasto sujo 10	1997.69	2000	1999.99	1188.61	1999.99	1999.86
Mata 11	1999	696.066	2000	2000	802.145	1892.67

Figura 24 – Exemplo de uma matriz de separabilidade das assinaturas. Distâncias calculadas pelo método da divergência transformada.

43. Caso haja dificuldades na visualização da matriz gerada pelo ERDAS IMAGINE, você poderá visualizar a matriz no Excel. Clique com o botão direito do mouse sobre o título de uma coluna qualquer. No menu aberto escolha Export. Um quadro será aberto permitindo salvar a matriz em formato *.dat. Este arquivo pode ser importado pelo Excel. Outra opção, é selecionar no menu aberto a opção Select all e em seguida Copy, abrir uma planilha em branco no Excel e simplesmente colar a seleção.
44. Verifique as possíveis causas de valores abaixo de 1700 na matriz. Se forem duas amostras de uma mesma classe, por exemplo, mata 1 e mata 2, pode ser conveniente agrupá-las. Selecione as amostras no quadro Signature Editor e no mesmo quadro acesse o menu Edit | Merge. As amostras serão agrupadas em uma nova classe e serão mostradas no quadro Signature Editor. Você poderá editar seu nome e cor e apagar as amostras que deram origem ao agrupamento. Caso as amostras com baixa separabilidade sejam realmente de classes diferentes, verifique se o posicionamento delas está correto e se a delimitação delas não precisa de ajustes (pode ser que estejam incluindo pixels característicos de outras classes). Caso esteja tudo correto, possivelmente a resposta espectral de ambas as classes deve ser muito semelhante e provavelmente o algoritmo de classificação não fará uma perfeita distinção entre as duas classes. Estude a possibilidade de agrupá-las em uma categoria de classe maior, por exemplo, se amostras da classe culturas perenes não dão boa separabilidade com as amostras da classe culturas anuais, estude a possibilidade de agrupá-las em uma única classe denominada agricultura.
45. Pode ocorrer que duas amostras de uma mesma classe tenham uma separabilidade ótima. Nesse caso, após verificarmos se não há erros de posicionamento ou delimitação das amostras, poderemos deixá-las separadas no processo de classificação. As duas classes distintas que serão geradas poderão ser agrupadas num processo de pós-classificação, caso seja conveniente.
46. O ERDAS IMAGINE possui algumas ferramentas que permitem avaliar graficamente a separabilidade das assinaturas. Pode-se obter simultaneamente o histograma de duas ou mais assinaturas para cada banda de uma imagem e verificar se há sobreposição entre eles. Dois histogramas com grande área de sobreposição indicam má separabilidade entre as assinaturas que eles representam. A Figura 25 mostra simultaneamente os histogramas de duas assinaturas obtidas a partir de uma imagem Landsat. Observe uma grande sobreposição dos histogramas obtidos para banda 8; portanto, a banda 8 não é adequada para um processo de classificação que utilize essas assinaturas. Por outro lado, não há sobreposição dos histogramas na banda 3, o que indica uma ótima separabilidade entre as assinaturas que eles representam.

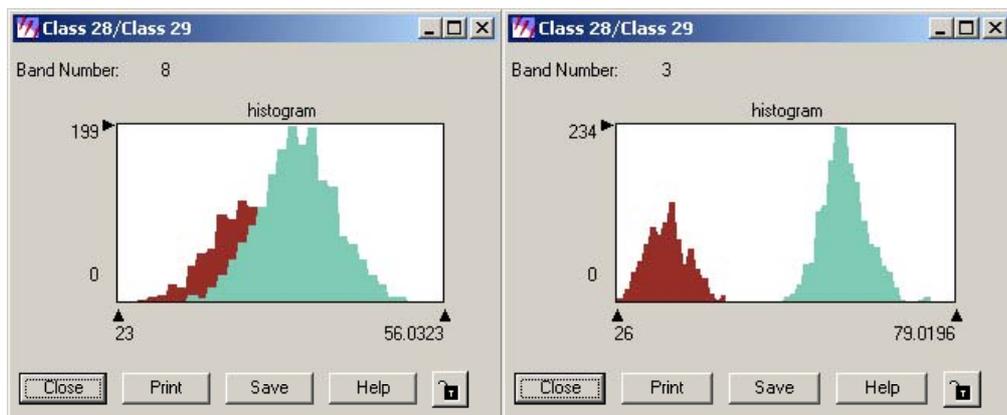


Figura 25 - Histogramas de duas assinaturas exibidos simultaneamente. Os histogramas para a banda 8 (à esquerda) possuem grande área de sobreposição, o que indica uma má separabilidade dessas assinaturas na banda 8. O mesmo não ocorre com os histogramas das mesmas assinaturas para a banda 3 (à direita).

47. Para obter o histograma de uma ou várias assinaturas, no quadro Signature Editor selecione a(s) assinatura(s) desejada(s), abra o menu View do mesmo quadro e escolha a opção Histograms. O quadro Histogram Plot Control Panel (Figura 26) será aberto. Escolha as opções All Selected Signatures e All Bands para obter o histograma de todas as bandas da imagem ou Single Band, para obter o histograma de apenas uma banda. Neste caso, selecione a banda desejada na caixa "Banda No" . Em seguida clique sobre Plot ou selecione a opção Auto Plot para ver a plotagem dos histogramas na tela. A Figura 27 apresenta os histogramas de uma única assinatura obtidos para todas as bandas de uma imagem Landsat. Caso tenha selecionado várias assinaturas, os histogramas para cada banda serão mostrados no mesmo quadro, como na Figura 25, o que permite verificar ocorrências de faixas espectrais onde as assinaturas se sobrepõem em cada banda.



Figura 26 – Quadro com as opções para plotagem de histogramas

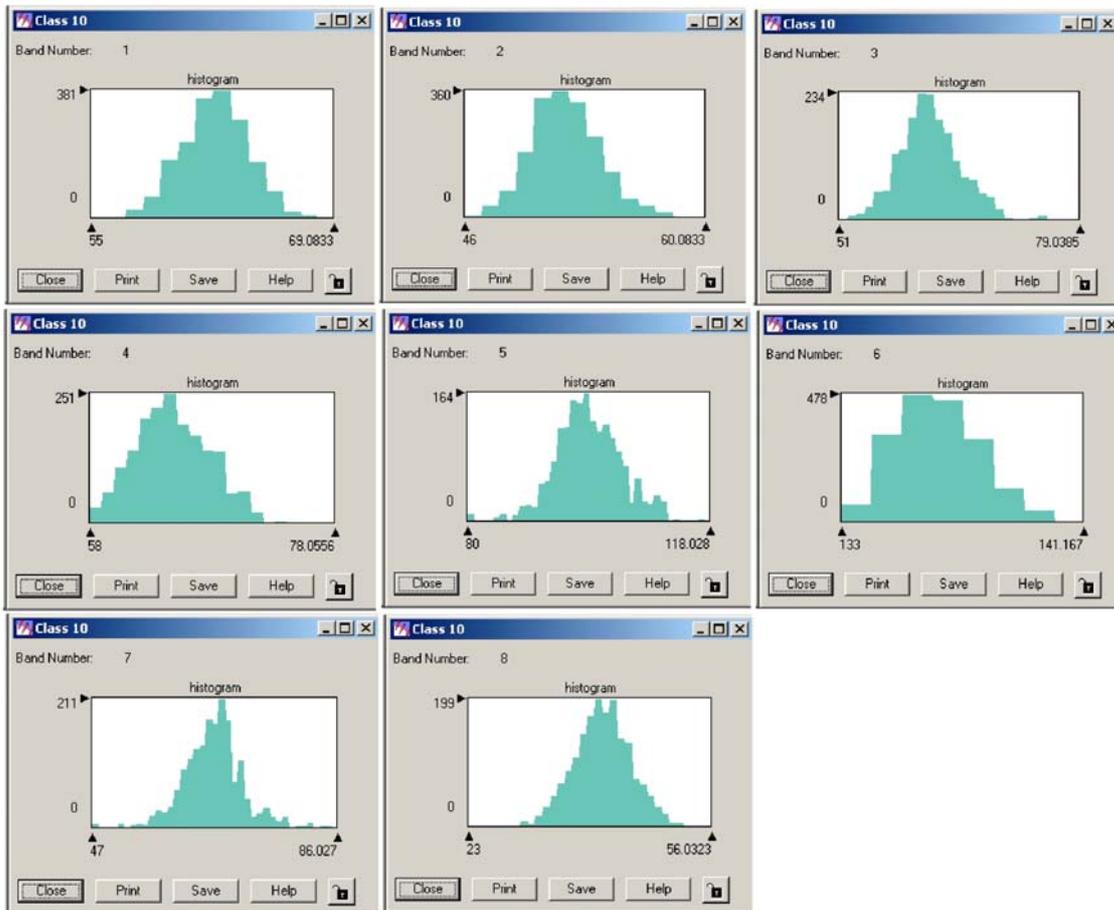


Figura 27 – Histogramas de uma assinatura obtidos para oito bandas de uma imagem Landsat.

48. Os histogramas também são úteis para uma checagem visual da normalidade da distribuição da resposta espectral de uma assinatura, condição necessária quando se utiliza o classificador de máxima verossimilhança. Observe o histograma da Figura 28. A distribuição da resposta espectral da assinatura que ele representa aparenta ser bimodal. Isso indica que o conjunto de treinamento escolhido pelo analista para representar a classe é composto por duas subclasses com características espectrais levemente diferentes. A acurácia da classificação será geralmente melhorada se cada uma dessas subclasses for tratada como classes distintas.

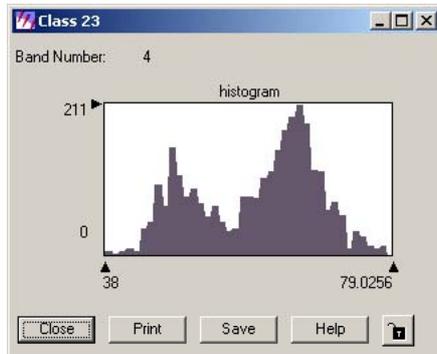


Figura 28 – Histograma mostrando uma distribuição da resposta espectral bimodal.

49. As assinaturas também podem ser avaliadas graficamente pelo Signature Mean Plot. O acesso a essa ferramenta é feito pelo menu View | Mean Plots do quadro Signature Editor. Veja um resultado obtido usando essa ferramenta (Figura 29). Assinaturas que possuem curvas semelhantes, possivelmente não têm boa separabilidade. Observe que no eixo X estão as bandas da imagem (8 bandas) e no eixo Y o valor médio dos pixels da amostra. Assinaturas com má separabilidade para determinada banda apresentam seus valores médios muito próximos. Caso um grande número de amostras de categorias diferentes apresentem valores médios bem próximos para determinada banda, essa banda pode ser excluída do processo de classificação. É o que ocorre, por exemplo, com as bandas 1, 2, 6 e 8 para as amostras plotadas na Figura 29.

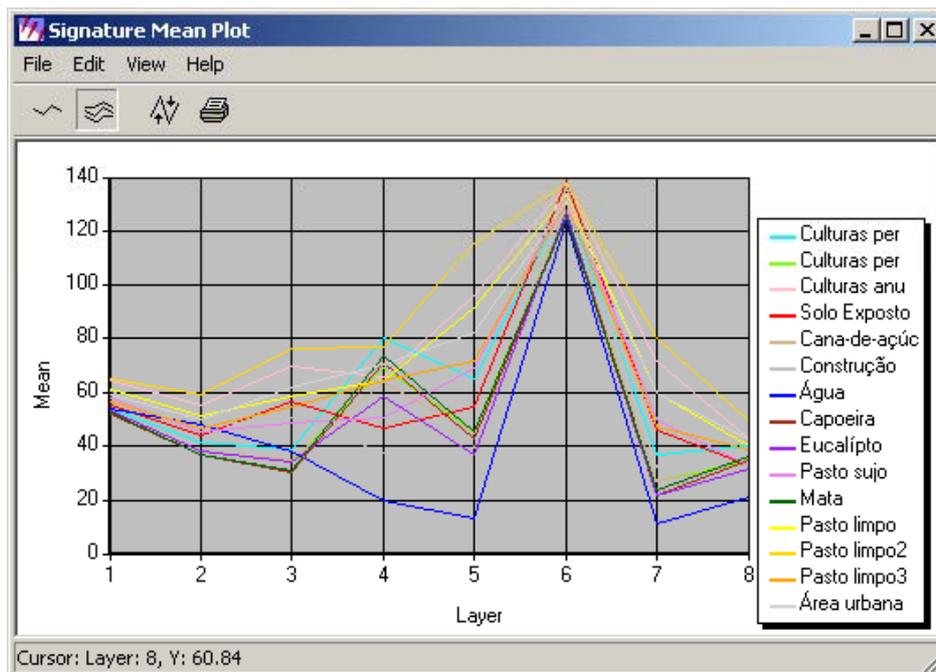


Figura 29 - Plotagem do valor médio dos pixels que compõem as amostras de treinamento para cada uma das bandas de uma imagem com 8 bandas.

50. Obtenha o gráfico dos valores médios dos pixels das assinaturas que você coletou. Provavelmente, o gráfico indicará a má separabilidade de muitas assinaturas nas bandas 1 e 2, e também nas bandas 6 e 8, caso você já não as tenha excluído do processo de avaliação da separabilidade. Escolha as bandas que apresentem, em média, a melhor separabilidade entre as assinaturas coletadas para o processamento da classificação. Clique em Edit no menu do quadro Signature Editor e selecione Layer Selection. Em Layer to Use, selecione as bandas desejadas. Basta clicar sobre elas com a tecla Shift acionada. (Figura 30). Em imagens Landsat, as bandas que costumam apresentar os melhores resultados na avaliação da separabilidade de assinaturas de classes de uso e cobertura das terras são as bandas 3,4,5 e 7.

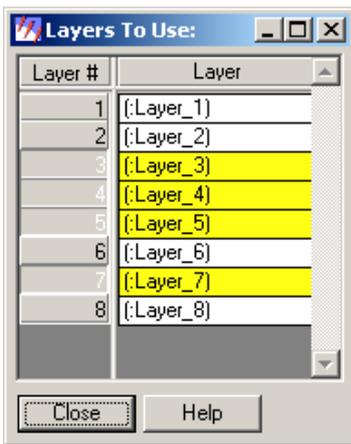


Figura 30 – Seleção das bandas que serão utilizadas no processo de classificação.

51. No quadro Signature Editor verifique novamente se a coluna I de cada assinatura está assinalada e se o número de pixels de cada assinatura é igual ou superior a ao número de bandas selecionadas mais um, condições necessárias para usar o algoritmo de máxima verossimilhança no processo de classificação.
52. Os processos de avaliação da separabilidade de assinaturas por meio de gráficos e por meio de métodos numéricos, como o da divergência transformada, podem ser usados simultaneamente. Uma indicação de má separabilidade no método numérico, pode eventualmente ser mais bem analisada com os histogramas ou gráfico de valores médios.

Processamento da classificação

53. Após a introdução de todas as amostras, a avaliação das separabilidades, a fusão, eliminação e correção das amostras de treinamento, podemos acessar o menu de classificação. No quadro Signature Editor clique em Classify| Supervised. Complete o quadro aberto conforme a Figura 31, escolhendo uma pasta e um nome para a imagem de saída (Output File). No mesmo quadro clique em Attribute Options e preencha o quadro Attribute Options se você quiser que o ERDAS IMAGINE gere estatísticas das amostras por banda da imagem. Ao clicar em OK o processo de classificação será iniciado. Terminado o processo, abra um visor e visualize a imagem classificada (camp_classsup.img).

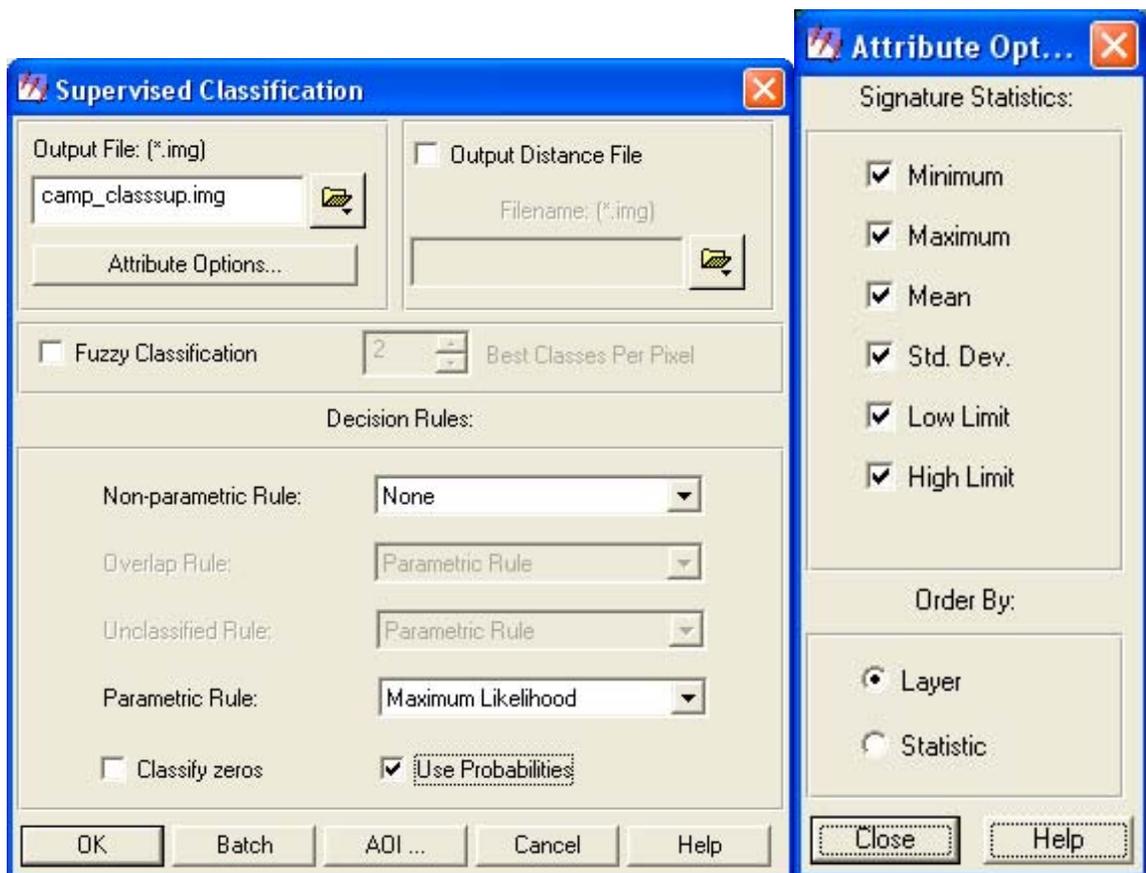


Figura 31 – Quadro que permite atribuir um nome para a imagem classificada e definir as regras de decisão da classificação supervisionada.

54. Para alterar a cor de visualização das classes, acione o menu Raster do visor onde a imagem classificada está aberta e selecione Attributes. No quadro Raster Attribute Editor, clique com o botão direito do mouse sobre a cor que você deseja alterar e escolha uma nova no menu aberto. A imagem pode ainda passar por um processo de filtragem igual ao que foi visto anteriormente para a classificação não supervisionada.
55. Após proceder todas as alterações e filtrações desejadas, salve a imagem temática, e acesse seus atributos (menu Raster| Attributes). O quadro Raster Attribute Editor será apresentado (Figura 32). Anote o nome de todas as classes presentes e o número correspondente a cada classe, apresentado na coluna ROW. Esse número identifica a classe e será usado no processo de avaliação da acurácia.

The screenshot shows the 'Raster Attribute Editor' window for a file named 'camp_classsupfilt.img(:Layer_1)'. The window has a menu bar with 'File', 'Edit', and 'Help'. Below the menu bar is a toolbar with icons for file operations and a 'Layer Number' dropdown set to '1'. The main area contains a table with the following data:

Row	Blue	Opacity	Class Name
0	0	0	Unclassified
1	0.67	1	culturas_anuais
2	0.25	1	água1
3	0.09	1	mata1
4	0.74	1	pasto2
5	0.71	1	solo exposto
6	0.67	1	urbana
7	0.22	1	café1
8	0.11	1	mata2
9	0.2	1	água2
10	0.74	1	pasto3

Figura 32 - Raster Attribute Editor. Anote o número atribuído para cada classe da imagem resultante da classificação (coluna Row).

Avaliação da Acurácia da Classificação

56. Clique sobre o ícone Classifier presente no painel de ícones do ERDAS IMAGINE.
57. No menu Classification selecione Accuracy Assessment. O quadro Accuracy Assessement será aberto (Figura 33).
58. Clique Close no quadro Classification para retirá-lo da tela.
59. No quadro Accuracy Assessment, selecione File | Open e abra a imagem classificada: resultante do exercício anterior.
60. Clique OK.
61. No visor Accuracy Assessment, selecione View | Select Viewer. Um quadro de instruções será aberto (Figura 34). Clique no visor que mostra a imagem classificada.
62. É necessário escolher cores para a representação dos pontos aleatórios que serão usados na avaliação da acurácia. No quadro Accuracy Assessment, selecione View | Change Color. Escolha a branca para os pontos sem referência (Points with no reference) e a cor preta para os pontos com referência (Points with reference) (Figura 35).

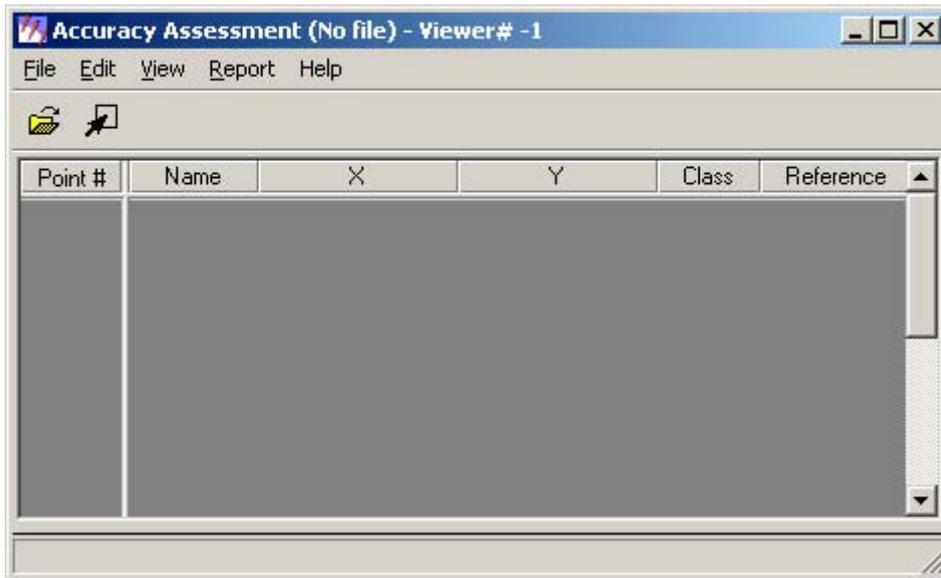


Figura 33- Quadro usado para a avaliação da acurácia (Accuracy Assessment).

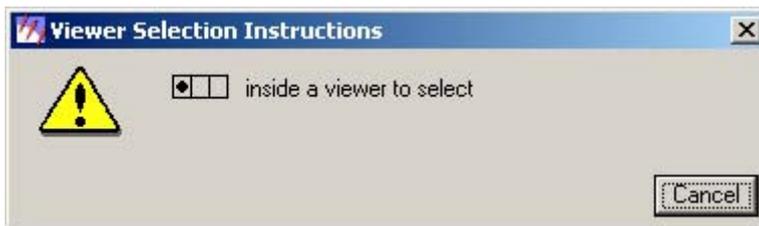


Figura 34 – Instrução para selecionar o visor onde a imagem classificada está aberta.

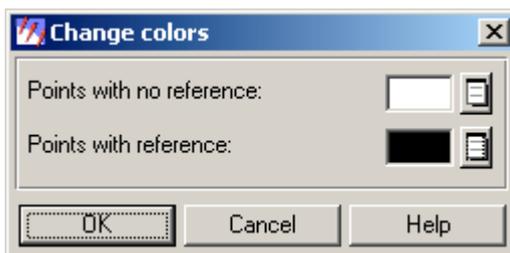


Figura 35 – Quadro usado para alterar as cores dos pontos que serão usados no processo de avaliação da acurácia

63. No quadro Accuracy Assessment, selecione Edit | Create/Add Random Points. Preencha o quadro Add Random Points conforme a Figura 36. Serão gerados 50 pontos aleatórios distribuídos por todas as classes verificadas no processo de classificação, com um número mínimo de 4 pontos por classe. Leia as notas a seguir antes de prosseguir o exercício.

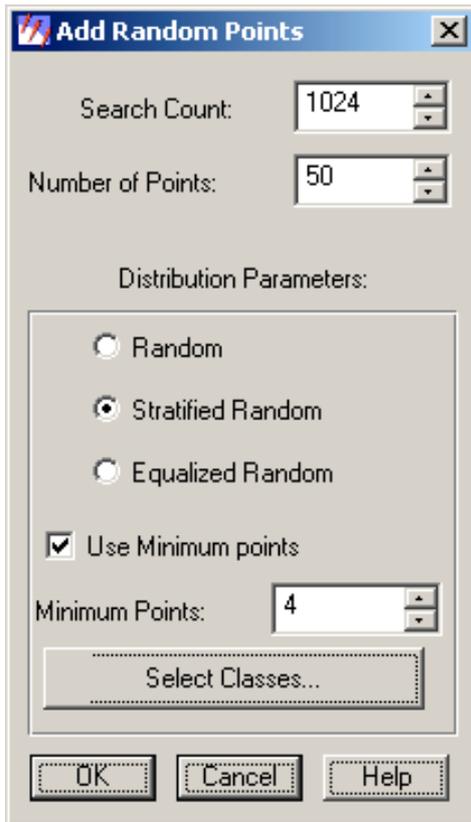
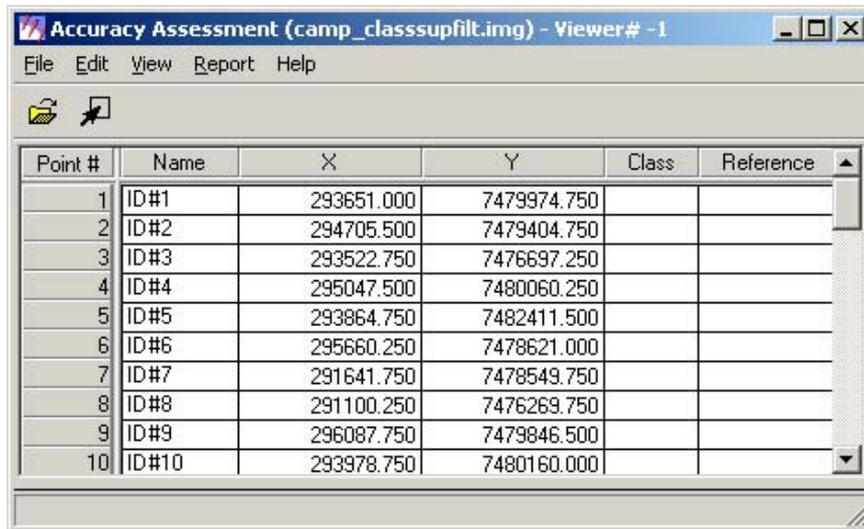


Figura 36 – Seleção dos parâmetros da distribuição dos pontos aleatórios.

Notas:

- Neste exercício serão gerados 50 pontos, entretanto, para uma avaliação apropriada da acurácia recomenda-se gerar pelo menos 250 pontos (ERDAS, 1999).
- O Search Count igual a 1024 significa que 1024 pontos serão analisados para ver se eles atendem os requerimentos do quadro Add Random Points. Se solicitada a geração de um grande número de pontos aleatórios, pode ser necessária a análise de um número maior de pontos. Nesse caso, você tem a opção de parar nos 1024 pixels analisados (ou outra quantidade que você escolher) ou continuar a gerar pontos aleatórios até completar o número de pontos aleatórios solicitado.
- Os pontos gerados podem ser completamente aleatórios (opção random), aleatórios mas estratificados (todas as classes da imagem classificada terão pelo menos um ponto aleatório), ou ainda aleatórios equalizados (um mesmo número de pontos será gerado para cada classe da imagem temática).
- Se você escolheu a opção Stratified Random, poderá selecionar um número mínimo de pontos para cada classe (Minimum Points)..
- Se desejar gerar pontos aleatórios apenas para determinadas classes, clique em Select Classes e escolha as classes desejadas.

64. Clique OK no quadro Add Random Points. O quadro fechará automaticamente quando o processo for completado. Uma lista com as coordenadas dos pontos gerados será mostrada no quadro Accuracy Assessment (Figura 37).



Point #	Name	X	Y	Class	Reference
1	ID#1	293651.000	7479974.750		
2	ID#2	294705.500	7479404.750		
3	ID#3	293522.750	7476697.250		
4	ID#4	295047.500	7480060.250		
5	ID#5	293864.750	7482411.500		
6	ID#6	295660.250	7478621.000		
7	ID#7	291641.750	7478549.750		
8	ID#8	291100.250	7476269.750		
9	ID#9	296087.750	7479846.500		
10	ID#10	293978.750	7480160.000		

Figura 37 - Quadro Accuracy Assessment com as coordenadas dos pontos aleatórios gerados (colunas X e Y).

65. No quadro Accuracy Assessment, selecione View | Show All. Os pontos aleatórios gerados serão mostrados sobre a imagem (Figura 38).
66. A coluna Reference do quadro Accuracy Assessment deverá ser preenchida com os valores que representam as classes que os pontos pertencem na realidade. Para isso, é conveniente fazer visitas aos locais correspondentes aos pontos aleatórios, utilizando preferencialmente um aparelho de GPS para melhor localizá-los. Caso essas visitas não sejam possíveis, deve-se recorrer a uma outra fonte confiável de informação; por exemplo, fotografias aéreas e imagens de alta resolução que possam ser facilmente interpretadas
67. Neste exercício, utilizaremos como verdade de campo um mapa de uso e cobertura das terras de Campinas. Consideraremos que esse mapa não apresenta erros quanto às classes de uso e cobertura. Abra-o no mesmo visor onde está aberta a imagem classificada com os pontos aleatórios. O arquivo correspondente ao mapa (uso_cobertura_sad69.shp) encontra-se na pasta C:/Tutorial_Imagine/Dados
68. Caso o mapa apresente seus polígonos com alguma cor de preenchimento, altere-os para que apenas seus contornos sejam visíveis. O acesso a essa alteração é feito pelo menu Vector | Viewing Properties. No menu Vector, selecione a opção Attributes. Uma tabela com os atributos de cada polígono do mapa de uso e cobertura será apresentada. Para identificar a classe a qual cada ponto aleatório pertence na realidade, clique sobre um deles. O polígono do mapa de uso e cobertura que circunda esse ponto será destacado por uma cor diferente, assim como a linha correspondente na tabela de atributos (Figuras 39 e 40). Verifique, nessa tabela, a classe à qual o pixel pertence. A nomenclatura das classes usadas no mapa poderá diferir da que você usou na classificação. Tente fazer uma adaptação, por exemplo, você provavelmente encontrará no mapa pontos classificados como pasto sujo e outros classificados como pasto limpo. Se você não fez essa diferenciação na sua classificação, basta considerá-los simplesmente como pasto.

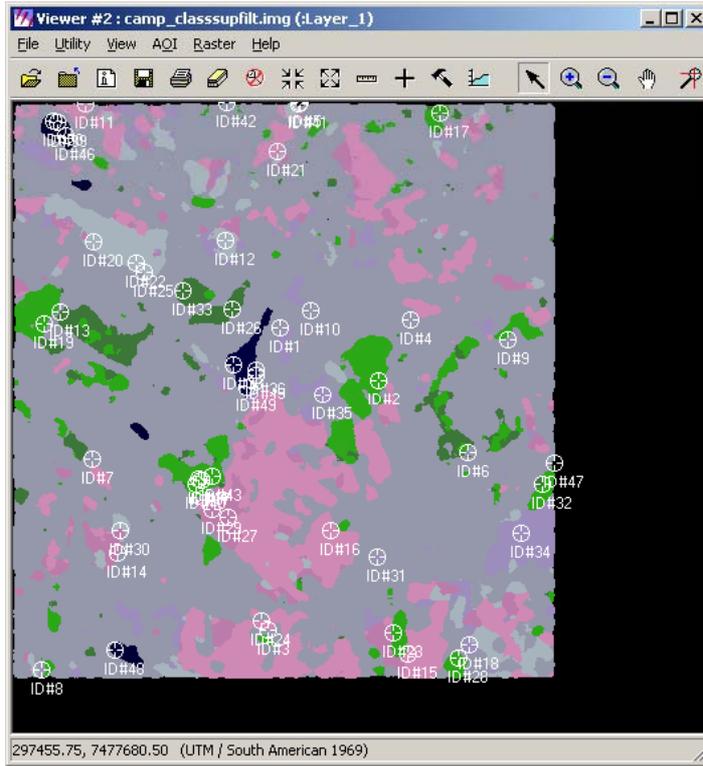


Figura 38 – Imagem com os pontos aleatórios gerados para o processo de verificação da acurácia.

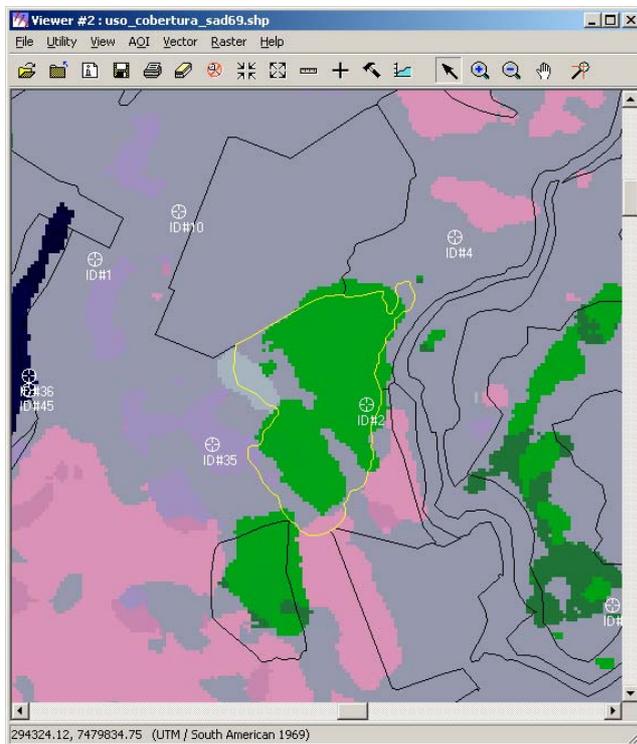


Figura 39 – Mapa de uso e cobertura das terras sobreposto à imagem classificada. Em destaque, o ponto aleatório #2, identificado no mapa de uso e cobertura como Floresta estacional semidecidual.

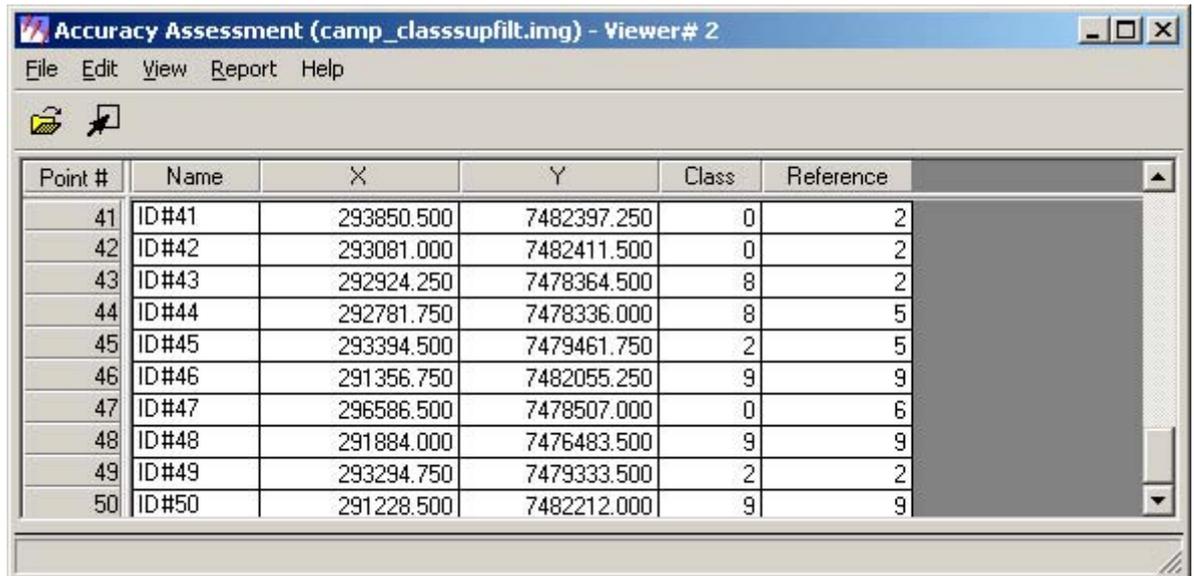
Record	AREA	CLASSE
377	49928.34	Capoeira
378	113864.33	Reflorestamento (eucalpto)
379	57797.06	Reflorestamento (eucalpto)
380	395804.34	Floresta estacional semi-decidual
381	977383.67	Cana-de-açúcar

Figura 40 – Tabela de atributos do mapa de uso e cobertura das terras mostrando, em amarelo, o registro do polígono selecionado na figura anterior.

69. Para facilitar o trabalho, você poderá anotar na tabela da página seguinte (Tabela 2), o nome das classes verificadas para cada ponto aleatório por meio da consulta ao mapa de uso e cobertura das terras ou mesmo a verdade de campo, caso tenha ido a campo para verificar o tipo de cobertura existente em cada ponto. Procure adequar a nomenclatura das classes àquela que você usou durante o processo de classificação da imagem. **Importante:** O Erdas Imagine durante o processo de avaliação da acurácia identifica as classes apenas por números. Portanto, na Tabela 2, preencha também o número que o Erdas Imagine atribuiu a cada classe de uso e cobertura. Foi solicitado que você anotasse esses números na etapa 55. Caso não tenha anotado esses números, você poderá acessar novamente o quadro Raster Attribute Editor, clicando no menu Raster do visor onde está aberta a imagem classificada e selecionando a opção Attribute (ver etapa 55).
70. Com o auxílio da Tabela 2 preenchida, volte ao quadro Accuracy Assessment e complete a coluna Reference com o número da classe para cada um dos pontos. À medida que você fornece o número da classe de referência para determinado ponto, sua marcação na imagem muda de cor.
71. No menu do Accuracy Assessment, selecione Edit | Show Class Values. A coluna Class (Figura 41) será preenchida com valores que representam as classes atribuídas aos pontos aleatórios no processo de classificação. Você poderá comparar os valores das colunas Class e Reference e ver quais foram os pontos classificados corretamente.
72. No quadro Accuracy Assessment, selecione Report | Options. As caixas de checagem Error Matrix, Accuracy Totals e Kappa Statistics deverão estar ativadas.
73. No quadro Accuracy Assessment, selecione Report | Accuracy Report. O relatório de avaliação da acurácia será mostrado em um editor de textos.(Figuras 42 e 43).
74. No quadro Accuracy Assessment, selecione Report | Cell Report. O relatório apresentado lista as opções e janelas utilizadas na seleção dos pontos aleatórios (Figura 44), além dos valores dos pixels de cada ponto aleatório gerado. No caso, cada ponto corresponde a uma célula de 3 X 3 pixels.
75. Caso deseje, salve os relatórios apresentados como arquivos de texto. Para fechar os editores de texto selecione File | Close
76. Para salvar a tabela do quadro Accuracy Assessment, clique em File | Save Table.
77. Se você está satisfeito com a acurácia da classificação, selecione File | Close.

Tabela 2 – Ficha para anotação das classes de uso e cobertura observadas nos pontos aleatórios gerados para a avaliação da acurácia da classificação.

No. ponto	Classe no mapa (verdade de campo)	Número da classe	No. ponto	Classe no mapa (verdade de campo)	Número da classe
1			26		
2			27		
3			28		
4			29		
5			30		
6			31		
7			32		
8			33		
9			34		
10			35		
11			36		
12			37		
13			38		
14			39		
15			40		
16			41		
17			42		
18			43		
19			44		
20			45		
21			46		
22			47		
23			48		
24			49		
25			50		



The screenshot shows a window titled "Accuracy Assessment (camp_classsupfilt.img) - Viewer# 2". The window has a menu bar with "File", "Edit", "View", "Report", and "Help". Below the menu bar are two icons: a folder and a magnifying glass. The main area contains a table with the following data:

Point #	Name	X	Y	Class	Reference
41	ID#41	293850.500	7482397.250	0	2
42	ID#42	293081.000	7482411.500	0	2
43	ID#43	292924.250	7478364.500	8	2
44	ID#44	292781.750	7478336.000	8	5
45	ID#45	293394.500	7479461.750	2	5
46	ID#46	291356.750	7482055.250	9	9
47	ID#47	296586.500	7478507.000	0	6
48	ID#48	291884.000	7476483.500	9	9
49	ID#49	293294.750	7479333.500	2	2
50	ID#50	291228.500	7482212.000	9	9

Figura 41 – Quadro Accuracy Assessment com as classes verificadas na imagem classificada (coluna Class) e as classes verificadas no mapa de referência (ou verdade de campo) para os pontos aleatórios utilizados na avaliação da acurácia da classificação.

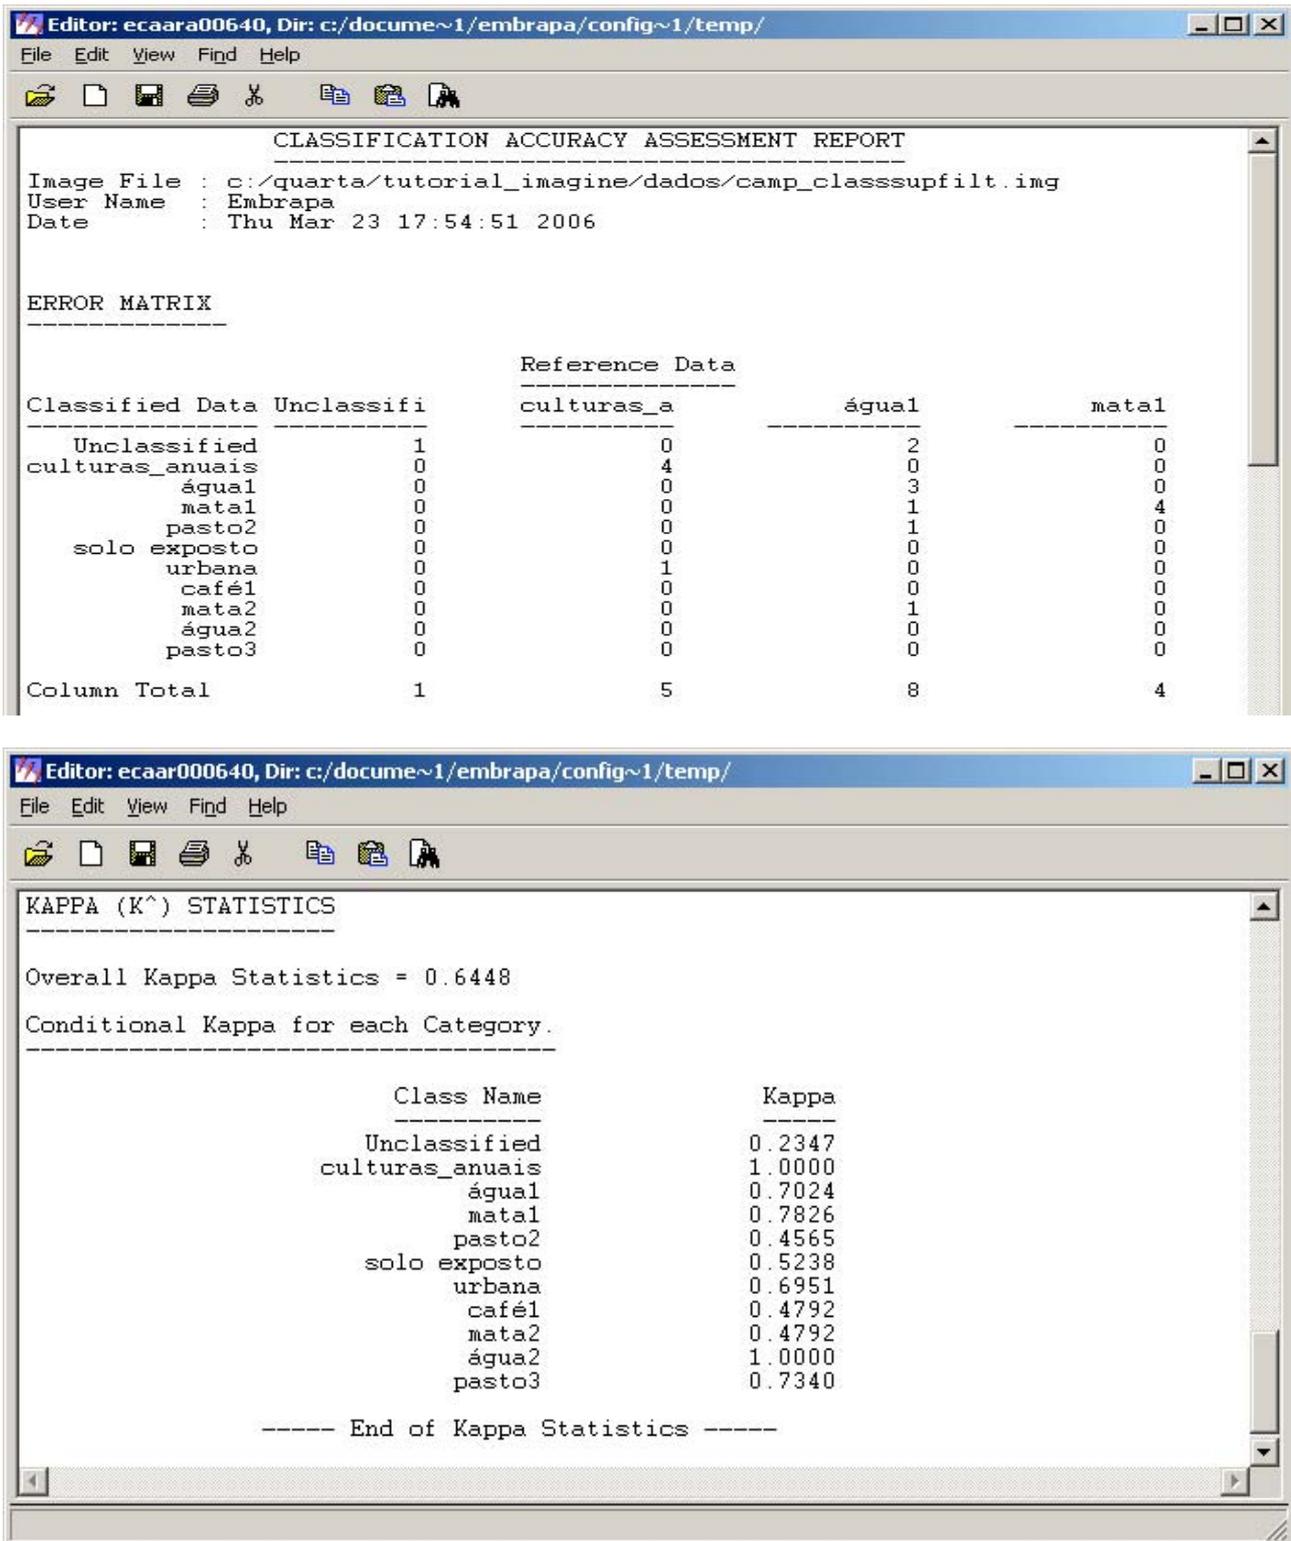


Figura 42 – Relatório de acurácia com a matriz de erros e os valores da estatística kappa.

Editor: ecaar000640, Dir: c:/docume~1/embrapa/config~1/temp/

File Edit View Find Help

ACCURACY TOTALS

Class Name	Reference Totals	Classified Totals	Number Correct	Producers Accuracy	Users Accuracy
Unclassified	1	4	1	---	---
culturas_anuais	5	4	4	80.00%	100.00%
água1	8	4	3	37.50%	75.00%
matal	4	5	4	100.00%	80.00%
pasto2	4	4	2	50.00%	50.00%
solo exposto	8	5	3	37.50%	60.00%
urbana	9	8	6	66.67%	75.00%
café1	2	4	2	100.00%	50.00%
mata2	2	4	2	100.00%	50.00%
água2	4	4	4	100.00%	100.00%
pasto3	3	4	3	100.00%	75.00%
Totals	50	50	34		

Overall Classification Accuracy = 68.00%

----- End of Accuracy Totals -----

Figura 43 – Relatório de acurácia, com o número de pontos de referência selecionados (Reference Totals), classificados (Classified Totals) e classificados corretamente (Number Correct) para cada classe, além das acurácias do produtor (Producers Accuracy) e do usuário (Users Accuracy) para cada classe e da acurácia geral (Overall Classification Accuracy).

```

Editor: kappa2, Dir: c:/trabalho_atual/
File Edit View Find Help
Imagine - ClassAcc (Classification Accuracy Assessment)
-----
Random Points Cell Listing
-----
Options Used in this run:
-----
Number of Points      : 50
Window Size          : 3
Window Majority Rule  : Clear Majority
No Majority Action    : Discard Window
Distribution          : Stratified Random

CELL 1 (6)           CELL 2 (3)           CELL 3 (6)           CELL 4 (6)
6 6 6               3 3 3               6 5 5               6 6 6
6 6 6               3 3 3               6 6 6               6 6 6
6 6 6               3 3 3               6 6 6               6 6 6

CELL 5 (0)           CELL 6 (6)           CELL 7 (6)           CELL 8 (6)
0 0 0               6 6 6               6 6 6               6 6 6
0 0 0               6 6 6               6 6 6               6 6 6
0 0 0               6 6 6               6 6 6               6 6 6

CELL 9 (6)           CELL 10 (6)          CELL 11 (5)          CELL 12 (4)
6 6 6               6 6 6               0 0 0               4 4 4
6 6 6               6 6 6               5 5 5               4 4 4
6 6 6               6 6 6               5 5 5               4 4 4

CELL 13 (7)          CELL 14 (1)          CELL 15 (5)          CELL 16 (5)
6 6 7               1 1 6               5 5 5               5 5 5
6 7 7               1 1 6               5 5 5               5 5 5
6 7 7               1 6 6               5 5 5               5 5 5

CELL 17 (3)          CELL 18 (10)         CELL 19 (3)          CELL 20 (4)
3 3 3               10 10 10            3 3 3               4 4 4
3 3 3               10 10 10            3 3 3               4 4 4
3 3 3               10 10 10            3 3 3               4 4 4

CELL 21 (5)          CELL 22 (4)          CELL 23 (3)          CELL 24 (5)
5 5 5               4 4 4               3 3 3               6 6 6
5 5 5               4 4 4               3 3 3               5 5 5

```

Figura 44 – Trecho do relatório dos pontos aleatórios. Os pontos aleatórios gerados correspondem a uma célula de 9 pixels (3X3 pixels). Alguns pontos podem conter pixels de mais de uma classe. Nesse caso, é atribuído ao ponto, o valor da classe majoritária da célula. A célula 14, por exemplo, contém cinco pixels da classe 1 e quatro da classe 6, portanto, o ponto é considerado como pertencente à classe 1.

Interpretação da Matriz de Erros

78. A matriz de erros apresenta em sua diagonal principal, a quantidade dos pontos selecionados para o teste de acurácia que foram classificados corretamente para cada uma das classes. As demais células da matriz apresentam a quantidade de pontos classificados incorretamente, tomando como referência (classe correta) a verdade de campo fornecida na coluna Reference do quadro Accuracy Assessment. A Tabela 3 apresenta uma matriz de erros hipotética. Podemos ver na linha da Classe A que do total de 13 pontos classificados como Classe A, 10 realmente pertencem à classe A, um pertence à classe B e dois pertencem à classe C. Por outro lado, na coluna da classe D, podemos ver que dos 11 pontos de referência pertencentes à classe D, 9 foram classificados para essa classe, mas 2 foram classificados para a classe C.

Tabela 3 – Exemplo de uma matriz de erros.

Dados Classificados	Dados de referência (Verdade de campo)				
	Classe A	Classe B	Classe C	Classe D	Total Linha
Classe A	10	1	2	0	13
Classe B	0	15	0	0	15
Classe C	0	5	12	2	19
Classe D	0	1	6	9	16
Total Coluna	10	22	20	11	63

79. A acurácia do produtor para determinada classe é o resultado da divisão do número de pontos classificados corretamente para essa classe pelo número total de pontos de referência que pertencem a essa mesma classe. Simplificando, é o número verificado na diagonal principal da matriz dividido pelo total da coluna correspondente à classe, considerando a configuração da matriz apresentada como exemplo. (Tabela 4).

80. A acurácia do usuário para determinada classe é o resultado da divisão do número de pontos classificados corretamente para essa classe pelo número total de pontos que foram classificados para essa mesma classe. Simplificando, é o número verificado na diagonal principal da matriz dividido pelo total da linha correspondente à classe, considerando a configuração da matriz apresentada como exemplo.

81. A acurácia global é a soma dos pontos classificados corretamente (soma dos elementos da diagonal principal da matriz) dividido pelo total de pontos usados no processo de avaliação da acurácia.

82. A acurácia do usuário indica a probabilidade de um pixel classificado dentro de uma determinada classe realmente pertencer a aquela classe no campo.

83. A acurácia do produtor indica a fração dos pixels de referência de determinada classe que foram classificados corretamente.

84. Veja na Tabela 4, os cálculos dos valores de acurácia, usando os dados da matriz de erro apresentada anteriormente.

Tabela 4 – Cálculo dos valores de acurácia para os dados da matriz de erros apresentada na Tabela 3.

	Acurácia do produtor	Acurácia do usuário
Classe A	10/10 = 100%	10/13 = 77%
Classe B	15/22 = 68%	15/15 = 100%
Classe C	12/20 = 60%	12/19 = 63%
Classe D	9/11 = 82%	9/16 = 56%
Acurácia Geral	(10 + 15 + 12 + 9)/63 = 73%	

Cálculo e interpretação da estatística Kappa

O coeficiente Kappa expressa a redução proporcional no erro gerado pelo processo de classificação comparado com o erro de uma classificação completamente aleatória. Por exemplo, um valor de 0,82 implica que o processo de classificação está evitando 82% dos erros que uma classificação completamente aleatória geraria (Congalton, 1991).

A estatística Kappa varia de 0 a 1. Um valor de Kappa igual a zero sugere que a classificação não é melhor do que uma classificação aleatória dos pixels. Um valor igual a um sugere um processo de classificação altamente eficiente. A fórmula utilizada para o cálculo do coeficiente Kappa (K) a partir da matriz de erros é apresentada na equação 1.

$$K = \frac{P_0 - P_c}{1 - P_c} \quad (\text{Equação 1})$$

$$P_0 = \frac{\sum_{i=1}^m n_{ii}}{N} \quad (\text{Equação 2})$$

$$P_c = \frac{\sum_{i=1}^m n_{i+} n_{+i}}{N^2} \quad (\text{Equação 3})$$

Onde,

P_0 é a acurácia geral;

P_c é a proporção de pontos que concordam por casualidade;

m é o número de classes presentes na matriz de erros;

n_{ii} é o número de observações da linha i e da coluna i (corresponde a um elemento da diagonal principal da matriz de erros);

n_{i+} é o total de observações da linha i da matriz de erros;

n_{+i} é o total de observações da coluna i da matriz de erros;

N é o número total de observações incluídas na matriz de erros.

Outra fórmula para o cálculo do Kappa é apresentada na Equação 4.

$$K = \frac{N \sum_{i=1}^m n_{ii} - \sum_{i=1}^m (n_{i+} \cdot n_{+i})}{N^2 - \sum_{i=1}^m (n_{i+} \cdot n_{+i})} \quad (\text{Equação 4})$$

Um exemplo do cálculo de Kappa para a matriz de erros da Tabela 3 é apresentado a seguir.

$$P_0 = \frac{10+15+12+9}{63} = 0,730$$

$$P_c = \frac{10 \times 13 + 22 \times 15 + 20 \times 19 + 16 \times 11}{63 \times 63} = \frac{1016}{3969} = 0,256$$

$$K = \frac{0,730 - 0,256}{1 - 0,256} = 0,637$$

Tomando como referência o relatório de acurácia da Figura 44, podemos calcular o valor de Kappa geral para aquela classificação que deverá coincidir com o Kappa geral apresentado no relatório da Figura 43. Na Figura 44, os valores da coluna References Totals são os totais das colunas da matriz de erros; os valores da coluna Classified Totals são os totais das linhas e os valores da coluna Number Correct são os valores da diagonal principal da matriz.

Portanto:

$$P_0 = \frac{1+4+3+4+2+3+6+2+2+4+3}{50} = 0,680$$

$$P_c = \frac{1 \times 4 + 5 \times 4 + 8 \times 4 + 4 \times 5 + 4 \times 4 + 8 \times 5 + 9 \times 8 + 2 \times 4 + 2 \times 4 + 4 \times 4 + 3 \times 4}{50 \times 50} = \frac{248}{2500} = 0,099$$

$$K = \frac{0,680 - 0,099}{1 - 0,099} = 0,6448$$

Uma das vantagens do cálculo do Kappa é a possibilidade do uso desse valor como uma base para determinar a significância estatística de uma matriz de erros ou a diferença entre duas matrizes. Pode-se querer, por exemplo, comparar as matrizes de erros resultantes da classificação de imagens de diferentes datas ou resultantes de diferentes técnicas de classificação. Testes estatísticos usando o Kappa podem determinar se uma matriz individual é significativamente diferente de um resultado aleatório e se o valor K de duas matrizes são significativamente diferentes um do outro. (LILLESAND et al, 2004)

Considerações Finais

As técnicas de classificação de imagens apresentadas nesse tutorial são apenas algumas das mais utilizadas na área. Existem outras técnicas que o leitor interessado poderá tomar conhecimento por meio da literatura especializada.

As técnicas aqui apresentadas não são exclusivas do Erdas Imagine. Existem outros softwares de processamento de imagens que também as executam, embora cada um tenha suas particularidades quanto à manipulação das imagens e ao acesso às suas funcionalidades

Referências

CRÓSTA, A. P. **Processamento digital de imagens de Sensoriamento Remoto**. Campinas: IG/UNICAMP, 1993. 170 p.

CONGALTON, R. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, n. 37, p. 35-46, 1991.

ERDAS. **Field Guide**. Atlanta: ERDAS, 1999. 672 p.

INPE. **SPRING**: Tutorial de Geoprocessamento. São José dos Campos: INPE, 2002. Disponível em: <<http://www.dpi.inpe.br/spring/portugues/tutorial/index.html>>. Acesso em: 30 nov. 2005.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote sensing and image interpretation**. 5. ed. New York: Wiley & Sons, 2004. 763 p.

MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e metodologias de aplicação**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2001. 250 p.

NOVO, E. M. L. M. **Sensoriamento Remoto: princípios e aplicações**. São Paulo: Edgard Blücher, 1992. 308 p.

QUARTAROLI, C. F.; BATISTELLA, M. **Processamento de Imagens de Sensoriamento Remoto: tutorial básico**. Campinas: Embrapa Monitoramento por Satélite, 2005. (Documentos 44).

RICHARDS, J. A. **Remote Sensing Digital Image Analysis: an introduction**. Berlin: Springer-Verlag, 1986. 281p.



Empresa Brasileira de Pesquisa Agropecuária

Embrapa Monitoramento por Satélite

Ministério da Agricultura, Pecuária e Abastecimento

Av. Dr. Júlio Soares de Arruda, 803 - Parque São Quirino

CEP 13088-300 Campinas-SP

Fone (19) 3256-6030 Fax (19) 3254-1100

<http://www.cnpm.embrapa.br> sac@cpnm.embrapa.br