

Método de extração de informações para monitoramento da ocupação das terras por grandes obras de infraestrutura a partir de imagens de satélite de alta resolução



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

Documentos 80

**Método de extração de informações para
monitoramento da ocupação das terras por
grandes obras de infraestrutura a partir de
imagens de satélite de alta resolução**

*Paulo Roberto Rodrigues Martinho
Wilson Anderson Holler
Evaristo Eduardo de Miranda
Cláudio Aparecido Spadotto*

Exemplares desta publicação podem ser adquiridos na:

Embrapa Monitoramento por Satélite

Av. Soldado Passarinho, 303 – Fazenda Chapadão
CEP 13070-115 Campinas, SP
Telefone: (19) 3211 6200
Fax: (19) 3211 6222
www.cnpm.embrapa.br
sac@cnpm.embrapa.br

Comitê Local de Publicações

Presidente: *Cristina Criscuolo*

Secretária-Executiva: *Shirley Soares da Silva*

Membros: *Bibiana Teixeira de Almeida, Daniel de Castro Victoria, Davi de Oliveira Custódio, Graziella Galinari, Luciane Dourado, Vera Viana dos Santos*

Supervisão editorial: *Cristina Criscuolo*

Revisão de texto: *Bibiana Teixeira de Almeida*

Normalização bibliográfica: *Vera Viana dos Santos*

Tratamento de ilustrações e editoração eletrônica: *Shirley Soares da Silva*

Ilustração da capa e ilustrações no documento: *arquivos da Embrapa Monitoramento por Satélite.*

1ª edição

1ª impressão (2010): versão digital.

Todos os direitos reservados.

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

Dados Internacionais de Catalogação na Publicação (CIP)

Embrapa Monitoramento por Satélite

Martinho, Paulo Roberto Rodrigues

Método de extração de informações para monitoramento da ocupação das terras por grandes obras de infraestrutura a partir de imagens de satélite de alta resolução / Paulo Roberto Rodrigues Martinho, Wilson Anderson Holler, Evaristo Eduardo de Miranda, Cláudio Aparecido Spadotto. – Campinas: Embrapa Monitoramento por Satélite, 2010.

21 p.: il. (Embrapa Monitoramento por Satélite. Documentos, 80).
ISSN 0103-78110.

1. Monitoramento orbital. 2. Sensoriamento remoto. I. Holler, Wilson Anderson. II. Miranda, Evaristo Eduardo de. III. Spadotto, Cláudio Aparecido. IV. Embrapa. Centro Nacional de Pesquisa de Monitoramento por Satélite (Campinas, SP). V. Título. VI. Série.

CDD 621.3678

© Embrapa Monitoramento por Satélite, 2010

Autoria

Paulo Roberto Rodrigues Martinho

Engenheiro Agrônomo, Mestre em Agricultura tropical e subtropical e Gestão de recursos ambientais,
Analista de Geoprocessamento
Embrapa Monitoramento por Satélite
paulo@cnpm.embrapa.br

Wilson Anderson Holler

Engenheiro cartógrafo, Analista de Geoprocessamento
Embrapa Monitoramento por Satélite
holler@cnpm.embrapa.br

Evaristo Eduardo de Miranda

Engenheiro Agrônomo, Doutor em Ecologia, Coordenador do Escritório de Análise de Imagens e Monitoramento por Satélite do Gabinete de Segurança Institucional da Presidência da República – GSI/PR em Campinas, SP
mir@cnpm.embrapa.br

Cláudio Aparecido Spadotto

Engenheiro Agrônomo, Doutor em Geociências e Meio Ambiente, Supervisor da área de Gestão Territorial Estratégica
Embrapa Monitoramento por Satélite
spadotto@cnpm.embrapa.br

Sumário

Resumo	5
Introdução	6
Material e métodos	9
Preparação das imagens	10
Resultados e discussão.....	18
Considerações finais	20
Referências	20

Ilustrações

Figura 1. Distribuição e tipificação das obras com interesse de monitoramento orbital do Programa de Aceleração do Crescimento (PAC).	8
Figura 2. Imagem Ikonos 2 da usina hidroelétrica, com AIO definida (A) e recortada (B).....	11
Figura 3. Informações estatísticas e de projeção da imagem do sensor Ikonos 2 (fundo), padronizada de acordo com os procedimentos propostos.	11
Figura 4. Detalhe das imagens do satélite Ikonos 2 com composição RGB 1, 2 e 3.	12
Figura 5. Caixa de editor de assinatura do Erdas aberto, mostrando algumas amostras coletadas na imagem (Solo Exposto), com a opção “região de crescimento” selecionada.	13
Figura 6. Caixa Signature Editor, com várias amostras de assinatura editadas e agrupadas.	13
Figura 7. Parte da tabela de matriz de separabilidade das assinaturas, gerada a partir das distâncias calculadas pelo método da divergência transformada.....	15
Figura 8. Imagem após classificação e aplicação do filtro.	16
Figura 9. Mapa de uso e cobertura das terras, classificado a partir da aplicação do algoritmo de máxima verossimilhança à imagem com resolução alterada da usina hidroelétrica tomada pelo satélite Ikonos 2, datada de 8 de janeiro de 2009.	17

Método de extração de informações para monitoramento da ocupação das terras por grandes obras de infraestrutura a partir de imagens de satélite de alta resolução

Paulo Roberto Rodrigues Martinho

Wilson Anderson Holler

Evaristo Eduardo de Miranda

Cláudio Aparecido Spadotto

Resumo

A tecnologia de sensoriamento remoto é uma das mais importantes fontes de informação para subsídios na identificação e no monitoramento de mudanças na cobertura da Terra. Objeto dessa tecnologia, a classificação supervisionada, por meio do algoritmo da máxima verossimilhança, tem sido um dos métodos mais utilizados para a extração de informações, principalmente em imagens de média resolução espacial. Utilizando parâmetros estatísticos, esse algoritmo pressupõe a ponderação das distâncias entre as médias dos níveis digitais das classes. Este trabalho objetivou a aplicação desse algoritmo em imagem de satélite de alta resolução. Para isso, foi necessário minimizar a intensidade de informações disponibilizadas por esses sensores, alterando a resolução espacial para 4 m e a radiométrica para 8 bit e, ainda, fazer uma filtragem pós-processamento. O presente trabalho, parte integrante de um projeto de monitoramento orbital de grandes obras de engenharia em infraestrutura, avaliou um método para a extração de informações para o monitoramento dessas obras, inseridas em meio rural ou urbano. A finalidade desse procedimento é subsidiar a análise da dinâmica de desenvolvimento dessas obras em relação a situações precedentes, assim como a possíveis intervenções no seu entorno. O projeto de monitoramento dessas obras utiliza imagens de satélites de vários sensores de alta resolução espacial, captadas em diferentes datas. No entanto, a aplicação do método apresentado neste trabalho exemplifica a utilização de imagem do satélite Ikonos 2 em uma única data. Para a imagem Ikonos 2, foi obtido um índice Kappa geral de 0,84 e apenas a classe caracterizada como Pastagem apresentou concordância relativamente mais baixa (0,71) em comparação a outras classes, mas ainda assim considerada uma boa classificação. Diante disso, a padronização proposta com a finalidade de minimizar as informações em imagens de alta resolução juntamente com o algoritmo da máxima verossimilhança e a posterior filtragem mostraram-se eficientes como suporte para a avaliação da ocupação das terras tomadas pelas obras (área de influência direta) e do seu entorno.

Introdução

Um dos processos mais utilizados para a extração de informação de imagens de satélite é a classificação de uso e cobertura das terras com base em técnicas de tratamento de imagens digitais. Nesse processo, os *pixels* de uma imagem são agrupados em classes de uso e cobertura das terras associadas a feições conhecidas.

Projetos desenvolvidos com essas técnicas geralmente cobrem áreas extensas e/ou de difícil acesso, o que requer procedimentos cada vez mais automatizados para a interpretação da paisagem. Nessas circunstâncias, o aumento da resolução espacial, radiométrica e espectral das imagens geradas pelos sensores atuais permitem ao analista identificar e mapear pequenos objetos na superfície terrestre (SUGUMARAN; ZERR, 2001), auxiliando na identificação das feições do terreno sem a necessidade de prospecções em campo, ou pelo menos com diminuição significativa dessas prospecções, e com admissão de erro minimizada.

Para Mendonça (2006, p.4),

a alta resolução espacial alcançada por esses novos sensores altera o modo como as imagens geradas são utilizadas no processo de classificação. Se anteriormente um *pixel* continha vários objetos, agora um objeto é composto por vários *pixels*, aumentando a percepção de detalhamento da cena.

Apesar de os sensores de alta resolução espacial apresentarem inúmeras vantagens, algumas questões importantes merecem destaque. Um exemplo é o aumento de possíveis problemas com sombras na superfície imageada. Segundo Ribeiro (2003), dependendo do ângulo de elevação solar, as sombras produzidas são mais proeminentes em imagens de alta resolução se comparadas às obtidas pelos sensores de menor resolução espacial. Essas sombras são difíceis de identificar e classificar e constituem fontes de erros em interpretação de imagens.

Para Fisher e Goetz (2001), “objetos tridimensionais interceptam a luz diferentemente e aparecem com iluminação e refletância espectral não uniformes”. Isso provoca um aumento na variação espectral em algumas feições e gera dificuldades na classificação (SUGUMARAN; ZERR, 2001).

Métodos de classificação baseados em *pixels* são amplamente utilizados em procedimentos de classificação em imagens de média e baixa resolução e têm sido utilizados ainda em imagens de alta resolução. No entanto, a tarefa de classificação de imagens de alta resolução pode ser considerada difícil, tendo em vista a elevada complexidade e composição dos tipos de cobertura do solo que podem ser discriminados nesse tipo de imagem, como demonstraram Masuoka et al. (2003).

Os métodos ou procedimentos de classificação digital de imagens são divididos em duas categorias: supervisionada e não supervisionada. A classificação não supervisionada é um método computacional automático de agrupamento com base nos valores presentes na imagem. Genericamente, cada *pixel* da imagem é associado a uma classe sem conhecimento prévio do número ou da identificação das diferentes classes presentes na área imageada (FONSECA, 2000). Já a classificação supervisionada necessita de conhecimento prévio da área para definir um conjunto de amostras de treinamento do

algoritmo representativo para cada classe de cobertura presente na imagem. Dessa forma, o sistema reconhece os diferentes intervalos do comprimento de onda e define os limites de cada classe (NOVO, 1992; RICHARDS, 1986).

Existem peculiaridades entre os métodos de classificação citados, com associação da informação espectral feita *pixel* a *pixel* ou por região: (i) *pixel* a *pixel*, o algoritmo classificador utiliza a informação dos valores espectrais associados de cada *pixel* para achar regiões homogêneas e traça, assim, a probabilidade de um determinado *pixel* analisado pertencer ou não a uma determinada classe; (ii) por região, considera a variabilidade espacial e a textura natural.

O processo de decisão analisa um agrupamento de *pixels* como unidade de classificação e procura reconhecer áreas homogêneas com base nas propriedades espectrais e espaciais dessas áreas na imagem (MOREIRA, 2001). Como as imagens de alta resolução permitem identificar feições de uso, minimizando a necessidade de prospecções de campo, a classificação supervisionada destaca-se como a mais adequada.

O algoritmo da máxima verossimilhança pressupõe a ponderação das distâncias entre as médias dos níveis digitais das classes utilizando parâmetros estatísticos. Como é um método de classificação supervisionada, é fundamental definir um conjunto de amostras de treinamento para obter o diagrama de dispersão das classes. O diagrama permite calcular a probabilidade estatística de um determinado *pixel* pertencer a uma classe particular de cobertura da terra (LILLESAND et al., 2004 citado por MOREIRA et al., 2009). A boa classificação, nessa metodologia, exige um número elevado de amostras de treinamento.

Existem outros métodos de classificação supervisionada que merecem alguma citação, mas não são contemplados pelo software utilizado por este trabalho (ERDAS IMAGINE, 2010). São exemplos: distância euclidiana ou método Bhattacharya; alguns métodos menos tradicionais, como *Spectral Angle Mapper* (SAM), *Support Vector Machine* (SVM), árvore de decisão utilizando redes neurais etc.; métodos de classificação orientada a objetos, que vêm ganhando espaço no desenvolvimento de projetos voltados ao uso de imagens de alta resolução.

Este trabalho objetivou avaliar o resultado da aplicação do algoritmo de máxima verossimilhança a uma imagem de alta resolução alterada intencionalmente, de forma a minimizar a intensidade de informações disponibilizadas por esse sensor. Sua finalidade é a de subsidiar a análise da dinâmica de desenvolvimento e da ocupação das terras em relação a situações precedentes no espaço territorial da área de influência direta (AID) e do entorno de grandes obras de engenharia em infraestrutura do Programa de Aceleração do Crescimento – PAC – (Figura 1), inseridas em meio rural ou urbano.

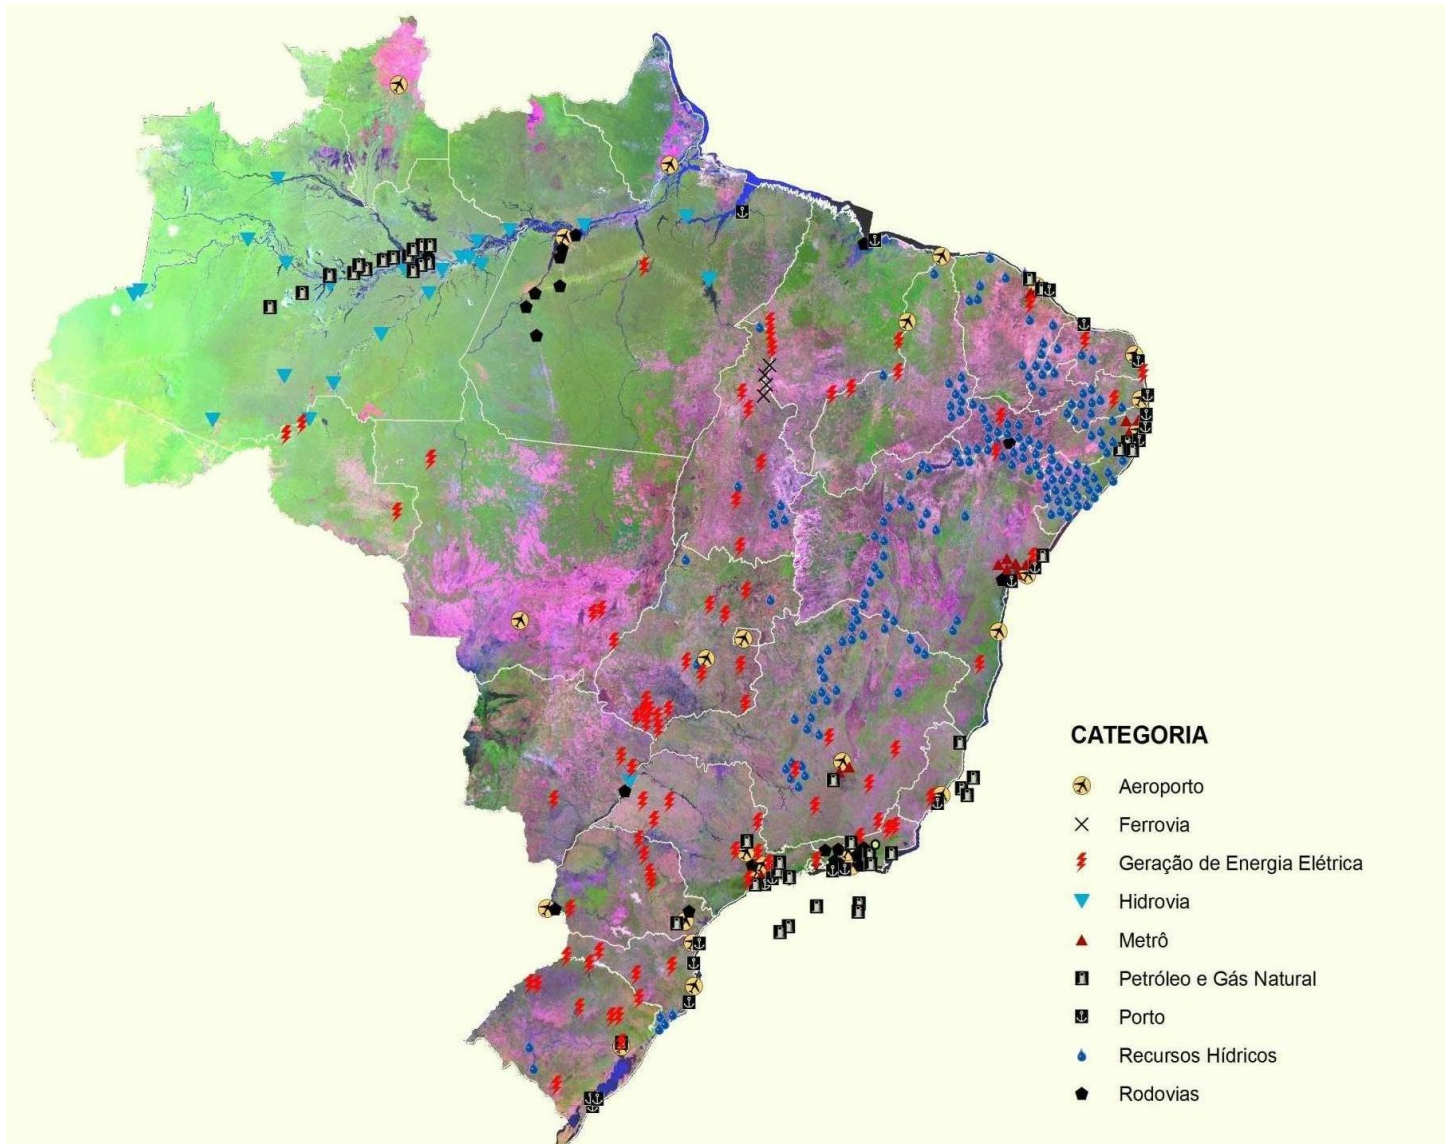


Figura1. Distribuição e tipificação das obras com interesse de monitoramento orbital do Programa de Aceleração do Crescimento (PAC).

Material e métodos

A Figura 1 apresenta a distribuição e tipificação de algumas obras envolvidas no Programa de Aceleração do Crescimento (PAC) no Brasil. É bom salientar que aproximadamente 300 áreas de interesse foram escolhidas para monitoramento orbital no âmbito do programa e que este trabalho não apresenta o total dessas obras.

No presente estudo, foram utilizadas as ferramentas do software Erdas Imagine 10 com apoio do software ArcGIS 9.3. O Erdas disponibiliza três métodos para processamento dos conceitos expostos: máxima verossimilhança (*maximum likelihood*), distância Mahalanobis (*Mahalanobis distance*) e distância mínima (*minimum distance*). O algoritmo utilizado neste trabalho foi obtido a partir de análise de máxima verossimilhança, por ser considerado o mais preciso dos classificadores implementados no software Erdas (ERDAS IMAGINE, 2010).

O projeto de monitoramento orbital das obras do PAC utiliza imagens de satélite de vários sensores de alta resolução espacial (Tabela 1) com aquisição de imagens em datas distintas e regulares para uma mesma obra. No entanto, a aplicação do método exemplifica o processamento em uma obra, data e imagem específica do Ikonos 2, e pode ser replicada em outros sensores (exceto no satélite Eros, que disponibiliza apenas a banda pancromática) e obras de interesse.

Tabela 1. Identificação e algumas características das imagens de satélites de alta resolução espacial utilizadas no monitoramento orbital das diversas obras do PAC.

Satélite	Bandas	Resolução	
		Espacial	Radiométrica
Ikonos 2	Multiespectral	4,00 m	11 bit
	Pancromática	1,00 m	11 bit
QuickBird	Multiespectral	2,40 m	16 bit
	Pancromática	0,60 m	16 bit
WorldView 2	Multiespectral	2,00 m	16 bit
	Pancromática	0,60 m	16 bit
Eros	Pancromática	0,70 m	10 bit

Primeiramente, foi padronizada a resolução das imagens de alta resolução. A resolução espacial foi alterada para 4 m e a radiométrica, para 8 bit com a finalidade principal de minimizar a intensidade de informações contidas nas imagens de alta resolução e, futuramente, de permitir a comparação dos resultados e a avaliação da dinâmica de desenvolvimento dessas obras durante a aplicação do método a outros sensores.

Na sequência, é apresentado um exemplo da aplicação dos procedimentos para classificação supervisionada em uma obra (usina hidroelétrica), data (8 de janeiro de 2009) e satélite específico (Ikonos 2).

A imagem foi padronizada da forma proposta, e a resolução radiométrica original da imagem do satélite Ikonos 2 foi reescalada de 11 bit (Tabela 1) para 8 bit. A resolução espacial (4 m) foi mantida, pois as bandas multiespectrais desse sensor já apresentam a indicação da resolução a ser padronizada.

É importante ressaltar que foi utilizada toda a resolução (sem alteração) disponibilizada pelo sensor e produzida pela fusão das bandas multiespectral e pancromática (fusão MSPan), para auxiliar a identificação das feições de uso e, assim, definir as amostras de treinamento de cada classe.

Foi discutida, ainda, a limitação do número de classes de uso para no máximo sete, sendo cinco o número ideal a ser utilizado quando possível. Restringir as classes significa facilitar as análises e simplificar as interpretações para os usuários do sistema de monitoramento orbital de obras do PAC, de outras áreas e para técnicos não especializados. Dessa forma, alguns temas foram agrupados em uma única classe, por exemplo:

- Áreas agrícolas: representam culturas perenes, anuais e pastagens;
- Matas: toda e qualquer cobertura florestal, nativa ou cultivada;
- Construções: áreas urbanas, obras em andamento, casas, barracões etc.;
- Água: qualquer curso d'água (rio, represas, lagos);
- Solo: solo exposto em áreas agrícolas, estradas de terra, canteiro de obras em andamento.

Apesar desse agrupamento de classes, alterações nessa nomenclatura podem ser realizadas por meio da criação de classes, de acordo com as necessidades pertinentes e específicas da região de cada obra.

Especificamente em alguns casos, pode ser necessário instituir uma classe “sem classificação”, devido à impossibilidade de analisar as feições do terreno causadas pela presença de nuvem e/ou de sombras dessas nuvens.

As imagens de alta resolução identificam sombras no terreno devido ao ângulo de incidência de luz em objetos com feições de dimensões diferenciadas, que dificulta o processo de classificação. Alguns exemplos encontrados foram: árvores isoladas, divisa entre mata e outra feição mais baixa (solo exposto, pastagem, rio) e edificações altas.

Para tornar o processo de classificação menos exaustivo, foi realizada a delimitação da área em torno da obra a ser classificada. Limitar o espaço físico de análise à área de influência direta (AID) da obra e seu entorno favorece o controle de setores dispensáveis (por exemplo, presença de nuvem) e atenua a necessidade de identificar novas e/ou outras classes de uso da terra, além de minimizar a possibilidade de confusão espectral.

Preparação das imagens

No processo de preparação da imagem, foi realizada a fusão das bandas multiespectrais (fusão MS) correspondentes às bandas azul, verde, vermelho e infravermelho próximo (*blue, green, red e near infrared*).

A partir dessa fusão, definiu-se visualmente uma área de interesse (*area of interest, AOI*) e recortou-se manualmente uma área irregular do entorno da obra (Figura 2A e B).




Figura 2. Imagem Ikonos 2 da usina hidroelétrica, com AIO definida (A) e recortada (B).

Após o recorte, foi realizada a padronização da imagem conforme o procedimento proposto e foi executado o reescalonamento da resolução radiométrica para 8 bit. Isso significa uma redução na escala original dos níveis de cinza de 2.048, referentes a 11 bit (Tabela 1), para 256.

Como a aplicação da metodologia exemplifica o processamento de uma imagem do satélite Ikonos 2, a reamostragem da resolução espacial não foi executada, pois a resolução espacial das bandas multiespectrais desse sensor já apresentam o valor proposto de 4 m.

Na Figura 3, são mostradas, em destaque, informações pertinentes ao processo de padronização. Em azul, é destacado o valor de 8 bit atribuído à resolução radiométrica e, em vermelho, são destacados os valores referentes ao tamanho do pixel de 4 m x 4 m, que determinam a resolução espacial da imagem. Ao fundo, é mostrada a imagem em falsa cor e padronizada.

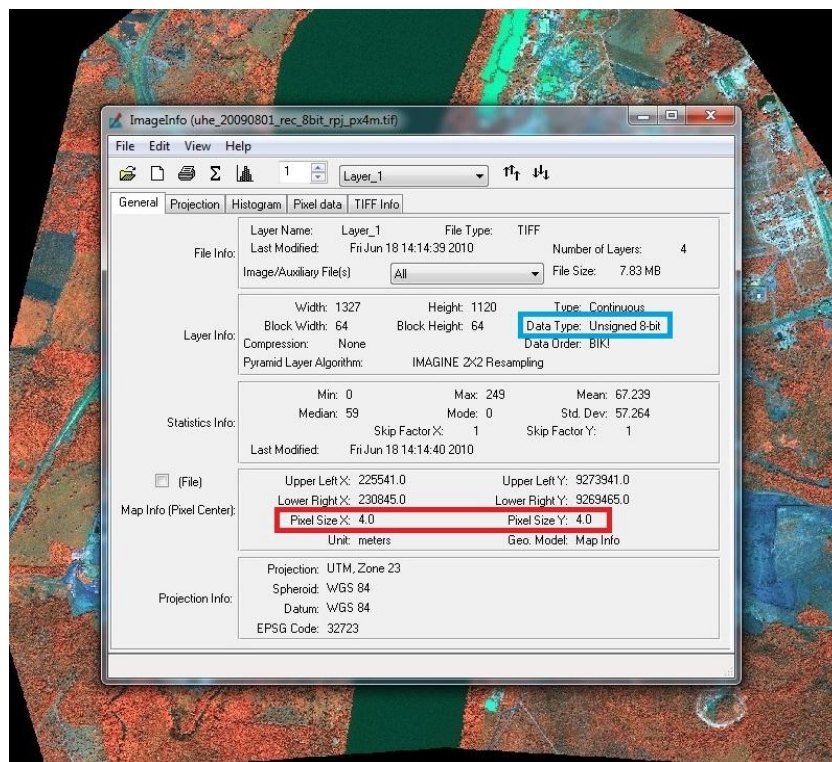


Figura 3. Informações estatísticas e de projeção da imagem do sensor Ikonos 2 (fundo), padronizada de acordo com os procedimentos propostos.

Após esses procedimentos, a imagem está pronta para o processo de classificação. No entanto, é bom ressaltar que o trabalho foi realizado com a imagem padronizada (Figuras 3 e 4A) concomitantemente com a imagem da fusão MSPan (Figura 4B), que disponibiliza a máxima resolução da imagem, com resolução espacial de 1 m e radiométrica de 11 bit (Tabela 1). Essa imagem serviu como referência para a identificação das feições no terreno.



A. Imagem de fusão MS padronizada.



B. Imagem de fusão MSPan original.

Figura 4. Detalhe das imagens do satélite Ikonos 2 com composição RGB, 1, 2 e 3.

Para iniciar o processo de classificação supervisionada, foi definido um conjunto de amostras de treinamento (assinaturas espectrais) representativas de cada classe de uso e cobertura das terras identificadas na imagem. Esse processo exige conhecimento da área em estudo, seja ele teórico (conhecimento do comportamento espectral dos alvos) ou prático, obtido em inspeções em campo, em mapas, na análise de fotografias aéreas ou de imagens de alta resolução (NOVO, 1992; RICHARDS, 1986).

Evitou-se a coleta de amostra de treinamento em áreas com alta probabilidade de confusão espectral, com sobreposição de informações de diferentes classes de uso. Um bom exemplo compreende regiões próximas a fronteiras entre feições distintas de uso e coberturas das terras identificadas na imagem.

O Erdas disponibiliza várias ferramentas para o processo de coleta de amostras de treinamento e delimitação de áreas representativas, e essas ferramentas são definidas por polígonos, elipses, retângulos ou “crescimento de regiões”.

Foi utilizada a opção de “crescimento de regiões”, que facilita a coleta de amostras e, principalmente, o controle dos níveis de cinza de uma amostra a ser coletada, e determina quais *pixels* possuem valores similares a um determinado *pixel* central. O analista escolhe o *pixel* central que deve representar a classe da qual se quer obter uma amostra de treinamento, e o programa agrega *pixels* adjacentes com valores similares segundo regras de configurações estabelecidas.

Foram definidas e capturadas várias amostras de treinamento para uma mesma classe em diferentes locais dentro da cena. “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*” (QUARTAROLI; BATISTELLA, 2006). A Figura 5 apresenta várias amostras representativas para Solo exposto (classes Class 1 a 8).

As várias amostras de treinamento definidas para uma mesma classe espectral foram coletadas e inseridas no programa separadamente (Figura 5). O Erdas trata-as inicialmente como se fossem de classes diferentes. A qualquer momento, é possível agrupá-las em uma única assinatura representativa para a classe.

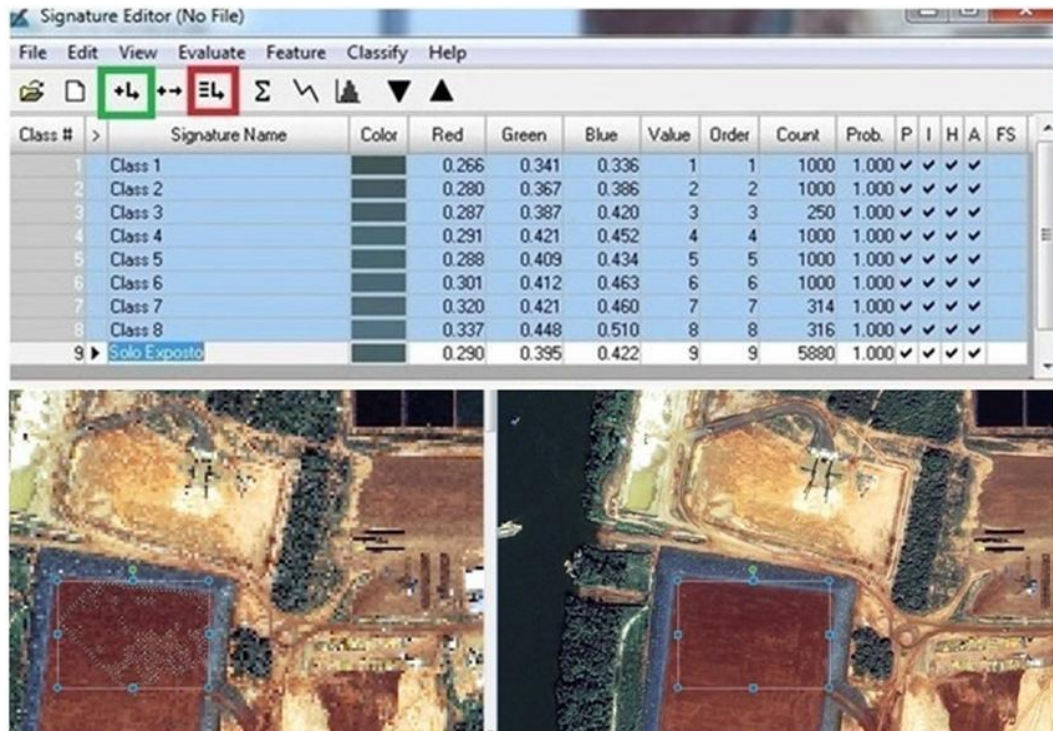


Figura 5. Caixa de editor de assinatura do Erdas aberto, mostrando algumas amostras coletadas na imagem (Solo Exposto), com a opção “região de crescimento” selecionada.

As assinaturas foram estratificadas em várias “subclasses”, de acordo com as características apresentadas na imagem. Um bom exemplo é a classe de solo exposto (Figura 5). Foi identificada visualmente na imagem mais de uma tonalidade de cor para essa mesma classe (solo marrom escuro, marrom claro, amarelo). Assim, foi válido diferenciar as tonalidades promovendo a coleta de amostras de treinamento separadamente e unificá-las somente após o processamento da classificação.

Na Figura 6, o quadro de assinaturas apresentado contém várias classes agrupadas. É possível verificar uma mesma classe identificada por várias subclasses, por exemplo: Solo (Solo verm. escuro, Solo verm. e Solo verm. amar.); Mata (Mata e Mata < densa); Água, estratificada em três subclasses; e assim por diante.

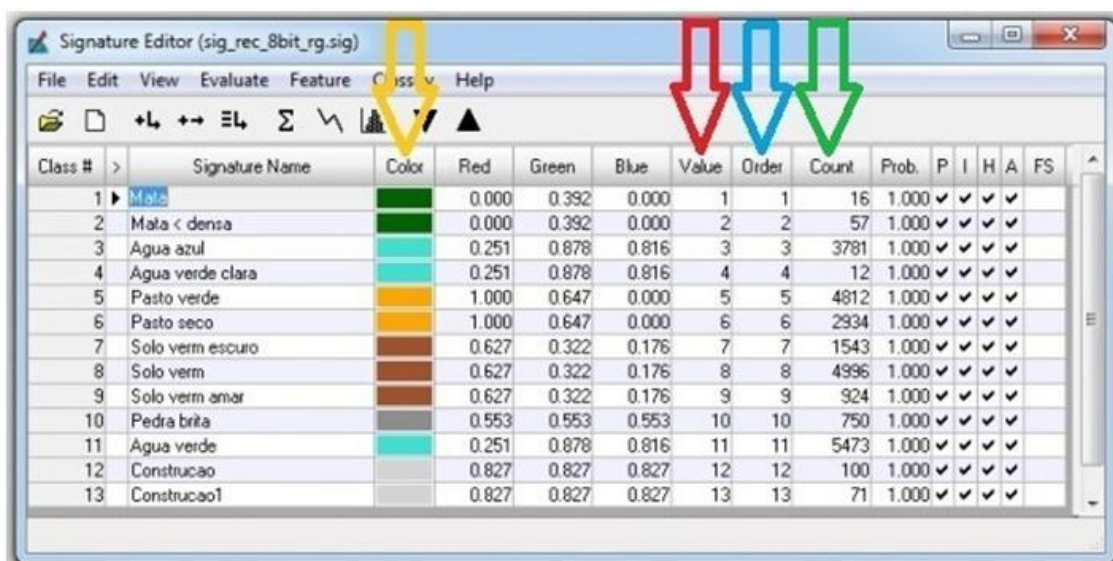


Figura 6. Caixa *Signature Editor*, com várias amostras de assinatura editadas e agrupadas.

Após a introdução de todas as assinaturas, foi verificado o número de *pixels* de cada assinatura para representar a classe (seta verde, Figura 6). Esses algoritmos auxiliaram na avaliação da separabilidade das assinaturas e no processo de classificação. Estatisticamente há uma exigência para o número de *pixels* a ser considerado para o processo. Contudo, na prática, quanto maior for o tamanho da amostra, melhor será a representação estatística da classe espectral (QUARTAROLI; BATISTELLA, 2006). Segundo Lillesand et al. (2004) citados por Quartaroli e Batistella (2006), o ideal é usar um valor entre $10n$ e $100n$ de *pixels* para compor uma assinatura, onde n representa o número de bandas da imagem. Como o sensor Ikonos 2 trabalha com quatro bandas multiespectrais (Tabela 1), é recomendável utilizar, para cada assinatura, um número entre 40 e 400 *pixels*.

As assinaturas identificadas como Mata e Água verde clara (linhas 1 e 4, respectivamente) na Figura 6 mostram valores menores que o recomendado. Portanto, retornou-se ao processo de coleta de amostras para fazer a agregação de novas amostras de treinamento a essas assinaturas.

Outras atribuições efetuadas na caixa *Signature Editor* (Figura 6) são a do valor e a da ordem (setas vermelha e azul, respectivamente). A organização sequencial dos valores atribuídos (por linha) é de grande valia após o processo de classificação, já que cada classe identificada assume os valores definidos nesse quadro e na ordem apresentada.

Em seguida, foi avaliado, na coluna "I" do mesmo do quadro, se as linhas correspondentes a cada assinatura estavam selecionadas (\checkmark). Isso significa que a matriz de covariância da assinatura pode ser invertida, condição necessária para usar as funções de divergência e máxima verossimilhança.

Ainda no quadro da Figura 6, foi alterada a cor atribuída automaticamente pelo Erdas (seta amarela) para uma cor disponibilizada no menu de palheta de cores. Foram escolhidas cores contrastantes para cada classe (nível de medida de representação cartográfica nominal), para facilitar sua visualização após o processamento.

Finalizado o processo de coleta de amostras de treinamento, foi verificada a confusão espectral atribuída às assinaturas por meio da avaliação da sua separabilidade. A separabilidade das assinaturas é uma medida estatística da distância espectral entre duas assinaturas (ERDAS IMAGINE, 2010). Essa distância determina quão distintas são umas das outras as assinaturas das classes definidas. Esse comando pode determinar também o melhor conjunto de camadas (bandas) para uso na classificação.

Foi utilizado o método da divergência transformada (*transformed divergence*) para a avaliação da separabilidade das assinaturas. De acordo com Jensen (1996) citado por Erdas Imagine (2010), a divergência transformada estima um peso exponencialmente decrescente para aumentar as distâncias entre as classes. A escala dos valores de divergência transformada varia de 0 a 2.000 e, quanto maior o valor, maior a separabilidade entre as classes. Para fins de comparação, a divergência transformada pode ser normalizada para uma faixa de variação determinada. Segundo o mesmo autor, a interpretação dos resultados sugere, como regra geral, que amostras bem separadas apresentam valores superiores a 1.900, e a separabilidade é considerada razoável quando os valores situam-se entre 1.700 e 1.900 e ruim com valores abaixo de 1.700. Na faixa abaixo de 1.700, a resposta espectral das classes é muito semelhante e o algoritmo de classificação provavelmente não fará uma distinção perfeita entre elas. A diagonal da matriz (referente à mesma assinatura) tem valores iguais a zero (Figura 7).

Signature Name	1	2	3	4	5	6	7	8
Mata < densa	1	0	2000	2000	2000	2000	2000	2000
Água azul	2	2000	0	2000	2000	2000	2000	2000
Pasto verde	3	2000	2000	0	1994.87	2000	2000	2000
Pasto seco	4	2000	2000	1994.87	0	2000	2000	2000
Solo verm escuro	5	2000	2000	2000	2000	0	1936.07	2000
Solo verm	6	2000	2000	2000	2000	1936.07	0	2000
Solo verm amar	7	2000	2000	2000	2000	2000	2000	0
Pedra brita	8	2000	2000	2000	2000	1999.99	2000	2000
Água verde	9	2000	2000	2000	2000	1999.99	2000	2000
Construcao	10	2000	2000	2000	2000	1999.25	2000	2000
Construcao1	11	2000	2000	2000	2000	2000	2000	2000
Mata	12	2000	2000	1995.73	2000	2000	2000	2000
Água verde clara	13	2000	2000	2000	2000	2000	2000	2000
Solo amar	14	2000	2000	2000	2000	2000	2000	2000
Construcao2	15	2000	2000	2000	2000	2000	2000	1998.25
Solo > amar	16	2000	2000	2000	2000	2000	2000	2000
Solo >> amar	17	2000	2000	2000	2000	2000	2000	2000

Figura 7. Parte da tabela de matriz de separabilidade das assinaturas, gerada a partir das distâncias calculadas pelo método da divergência transformada.

O quadro com a matriz de separabilidade definiu o grau de confiabilidade das amostras coletadas e foi ordenado em linhas e colunas (Figura 7). Na coluna *Signature Name* estão os nomes atribuídos a cada classe de assinatura seguidos de um número. Número da linha idêntico ao da coluna significa que os valores correspondem à mesma classe. Desse modo, foram comparadas todas as combinações possíveis entre as assinaturas coletadas. Por exemplo, a célula da linha 5 (Solo verm. escuro) com a coluna 1 (correspondente a Mata < densa) apresentou valor igual a 2.000. Concluiu-se, portanto, que há uma boa separabilidade entre essas duas amostras, segundo critérios de interpretação de Jensen (1996) citado por Erdas Imagine (2010). Foram identificados valores abaixo de 1.700 e verificadas as possíveis causas. Amostras de uma mesma classe foram agrupadas em uma nova classe e, para amostras de classes diferentes, foi conferido o posicionamento e sua delimitação e decidiu-se pela eliminação de uma ou de ambas as amostras, promovendo nova coleta.

O Erdas Imagine 10 disponibiliza outra ferramenta para avaliar a separabilidade das assinaturas, verificadas por meio do histograma das assinaturas de cada banda. Histogramas com grande área de sobreposição indicam má separabilidade. Essa foi uma atribuição importante, pois, além de auxiliar na avaliação da separabilidade das amostras, ajudou a verificar a contribuição de cada banda no processo de coleta das amostras. Em alguns casos, é possível definir se uma banda específica pode ser excluída do processo de classificação, minimizando a confusão espectral atribuída a essa banda.

Finalizado o processo de coleta e avaliação da separabilidade das amostras, foi promovida a classificação supervisionada pelo algoritmo da máxima verossimilhança.

A imagem processada foi observada visualmente e concomitantemente com a imagem da fusão MSPan e foi verificada a existência de áreas com erros de classificação. Desse modo, retornou-se ao processo de coletas de amostras de assinaturas. A separabilidade dessas novas amostras foi avaliada, e outro processo de classificação foi gerado e identificado com nome diferente do nome da versão anterior, para que elas pudessem ser comparadas. Todo esse processo foi repetido sucessivamente até que a classificação atendesse as necessidades da interpretação visual.

No entanto, verificou-se que a imagem estava muito poluída, ou seja, havia várias áreas pequenas representadas por *pixel* isolado ou pequenos grupos de *pixels*. Foi necessário promover a generalização dessas áreas, com aplicação de filtro. Na generalização, o *pixel* central assume o valor dos *pixels* vizinhos a partir da função aplicada e da quantidade de vizinhos usados.

O Erdas disponibiliza cinco funções diferentes para essa generalização e três janelas para definir o número de vizinhos (3×3 *pixel*, 5×5 *pixel* ou 7×7 *pixel*). Quanto maior é o número de *pixels*, maior é a generalização. Foram usadas a função *majority* (valor predominante) e janela de 3×3 *pixel* vizinhos, e o resultado é apresentado na Figura 8.




Figura 8. Imagem após classificação e aplicação do filtro.

Outro processo para generalizar a imagem após a classificação, antes ou mesmo depois da filtragem proposta, é o da eliminação dos polígonos menores do que uma área predeterminada, por exemplo, áreas de 16 m^2 (representadas por um *pixel*), 32 m^2 (1×2 *pixel*) ou 64 m^2 (2×2 *pixel*), conforme a necessidade verificada pela avaliação visual da imagem classificada. No entanto, os resultados obtidos no ArcGIS 9 para esse mesmo processo foram mais satisfatórios que aqueles obtidos no Erdas.

Para isso, foi promovida a vetorização da imagem *raster* (classificada) e foi gerado um arquivo vetorial (*arc coverage*) lido pelo ArcGIS 9.3. No ArcGIS, o arquivo *arc coverage* foi transformado em *shapefile*, condição necessária para o controle dos comandos de eliminação pelo ArcGIS. Nesse momento, promoveu-se a eliminação de todos os polígonos menores ou iguais a 16 m^2 . Finalizado o processo, observou-se a necessidade de eliminar polígonos com área diferente à estipulada e de classes específicas.

O processo de generalização foi finalizado e prosseguiu-se para a editoração (*layout*) do mapa de uso e cobertura das terras (Figura 9). Foram atribuídas cores correspondentes a cada classe e calculadas as áreas de ocupação de cada classe temática identificada no processo de classificação e a sua representatividade.

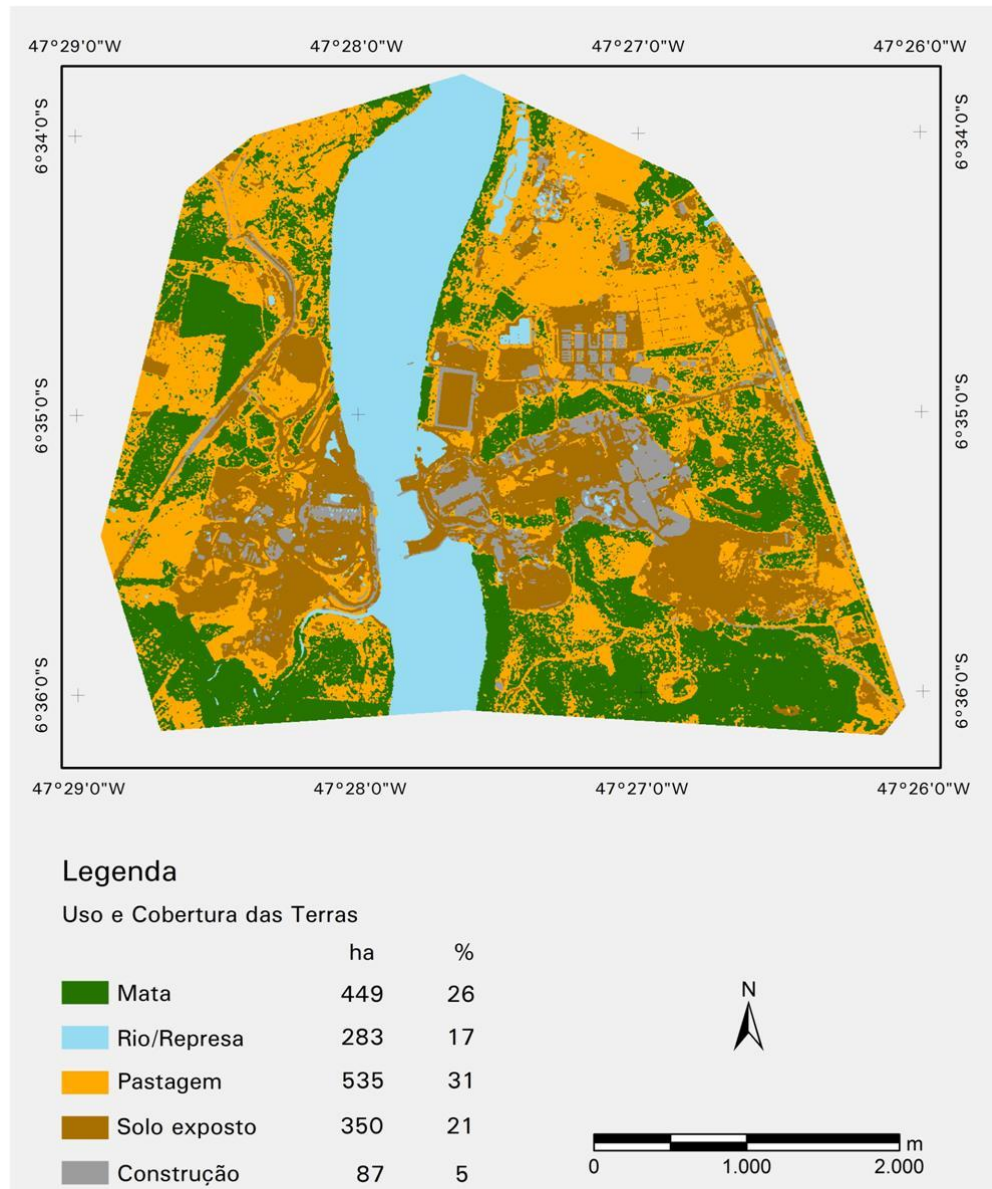


Figura 9. Mapa de uso e cobertura das terras, classificado a partir da aplicação do algoritmo de máxima verossimilhança à imagem com resolução alterada da usina hidrelétrica tomada pelo satélite Ikonos 2, datada de 8 de janeiro de 2009.

A partir desse momento, foi realizada a validação do resultado da classificação por meio da comparação do mapa obtido pela classificação com dados de referência (JENSEN, 1996 citado por MOREIRA et al., 2009) ou verdade de campo. A relação entre as classes identificadas (Figura 9) foi resumida em uma matriz de confusão (matriz de erro) ou tabela de contingência (LILLESAND; KIEFFER, 2004 citado por MOREIRA et al., 2009).

Foram consideradas como verdade de campo as feições identificadas na imagem da fusão MSPan (máxima resolução espacial e radiométrica disponibilizada pelo sensor Ikonos 2). Para tanto, foi feita a distribuição aleatória de 256 pontos de controle na imagem da fusão MSPan e a identificação visual do uso e, posteriormente, a comparação com as classes temáticas da imagem classificada (Figura 9) e a geração de uma matriz de erro (Tabela 2).

Resultados e discussão

A matriz de erros ou de confusão (Tabela 2) apresenta a tabulação cruzada entre os planos de informação referentes à interpretação visual da imagem da fusão MSPan do Ikonos 2, considerada como verdade campo (*pixels* de referência), e a classificação supervisionada (linhas). Ela identifica o erro global da classificação para cada classe temática e expõe como ocorreram os conflitos entre elas (BRITES, 1996), mas principalmente exhibe os *pixels* classificados corretamente na diagonal principal (azul). As exatidões do produtor e do usuário, valores inversamente proporcionais, representam os erros de omissão e inclusão, respectivamente.

A exatidão do usuário indica a probabilidade de um *pixel* classificado dentro de uma determinada classe realmente pertencer àquela classe. A exatidão do produtor indica se os *pixels* de referência de determinada classe estão classificados corretamente.

Erros de omissão acontecem quando determinada feição que deveria ser classificada em uma dada classe temática é classificada como pertencente a outra classe. Erros de inclusão surgem quando uma feição é classificada como pertencente a uma classe temática não correspondente à classe esperada (LEÃO et al., 2007).

Tabela 2. Matriz de confusão, em valores absolutos obtidos a partir da comparação entre a classificação supervisionada (classes) e verdade de campo (referência, imagem da fusão MSPan) do satélite de alta resolução Ikonos 2.

Classes	Pixels de referência = 256 (<i>pixels</i>)					Total/linha	Exatidão usuário*	Erro de inclusão*
	Mata	Rio/Represa	Pastagem	Solo exposto	Construção			
Mata	59	-	4	-	-	63	94	6
Rio/Represa	-	44	-	1	-	45	98	2
Pastagem	6	-	55	10	-	71	77	23
Solo exposto	-	-	1	49	2	52	94	6
Construção	-	-	-	2	23	25	92	8
Total/coluna	65	44	60	62	25	230		
Exatidão produtor*	91	100	92	79	92			
Erro de omissão*	9	0	8	21	8			

* valores expressos em porcentagem (%)

Exatidão da classificação geral = 90 %

	Imagem de referência (verdade de campo)
	Imagem a ser avaliada
	Linhas marginais
	Colunas marginais
	Diagonal - <i>pixels</i> classificados corretamente
	Somatório da diagonal - total de <i>pixels</i> classificados corretamente

Na linha 1, referente à classe Mata (Tabela 2), do total de 63 *pixels* avaliados: 59 foram classificados corretamente e 4, erroneamente, pois pertencem a outra classe (Pastagem), o que configura erro de inclusão.

A avaliação da coluna para a mesma classe (Mata) indica que 6 *pixels* pertencentes à classe Mata (verdade de campo) foram classificados como pertencentes a outra classe, o que configura erro de omissão, e assim sucessivamente para cada classe temática.

Em geral, as classes identificadas como Pastagem e Solo exposto apresentaram os maiores conflitos entre si. No entanto, a exatidão da classificação geral atingiu um alto índice de acerto (90%), atribuído ao total de *pixels* classificados corretamente (cor amarela), que representa a somatória da diagonal principal em relação ao total de *pixels* avaliados (256).

Colgaton (1991) citado por Moreira et al. (2009) e Gong e Howard (1990) citados por Brites (1996) sugerem o uso do coeficiente Kappa (K) como um dos procedimentos mais utilizados e satisfatórios para mensurar a exatidão das classificações temáticas, pelo fato de ele analisar toda a matriz de confusão no seu cálculo e considerar também os elementos de fora da diagonal principal, ou seja, as discordâncias da classificação, enquanto a exatidão global utiliza somente os elementos diagonais (concordância real).

Os valores do índice Kappa para as imagens Ikonos 2 geradas pelo Erdas para o processo de classificação supervisionada, considerado o algoritmo de máxima verossimilhança, são apresentados na Tabela 3.

O coeficiente de Kappa expressa concordância entre os valores reais (verdade de campo) versus o estimado (classificação) e avalia o erro gerado pelo processo de classificação devido ao acaso. Por exemplo, o valor de 0,84 alcançado pelo índice Kappa geral do estudo (Tabela 3) implica que o processo de classificação está evitando 84% dos erros que uma classificação completamente ao acaso geraria. Esse índice pode variar de -1 (discordância completa) a +1 (concordância completa). No entanto, não há definição precisa dos níveis de concordância aceitáveis. Para avaliar o índice Kappa foi utilizada a Tabela 4, adaptada de Galparsoro e Fernández (2001).

Tabela 3. Valores do índice Kappa individual e global para as imagens Ikonos 2 e método de classificação da máxima verossimilhança.

Classes	Índice Kappa
Mata	0,91
Rio/represa	0,97
Pastagem	0,71
Solo exposto	0,92
Construção	0,91
Índice Kappa geral = 0,84	

De acordo com os parâmetros adotados para avaliar os índices Kappa, a imagem temática (classificada) gerada pelo método descrito apresentou ótimos resultados, em sua grande maioria com concordância muito boa. Apenas a classe caracterizada como Pastagem apresentou concordância relativamente mais baixa (0,71) quando comparada a outras classes (Tabela 3), embora ainda assim tenha sido considerada como de boa concordância (Tabela 4).

Tabela 4. Valor para avaliar o grau de concordância a partir do índice Kappa.

Valor de Kappa	Concordância
< 0,20	Pobre
0,21 – 0,40	Fraca
0,41 – 0,60	Moderada
0,61 – 0,80	Boa
0,81 – 1,00	Muito boa

Fonte: Adaptado de Galparsoro e Fernández (2001).

Considerações finais

A padronização proposta mediante alteração da resolução espacial e radiométrica permitiu a comparação entre diferentes sensores, mas, principalmente, minimizou a intensidade de informações disponibilizadas pela imagem de alta resolução e, assim, admitiu a utilização de um método comumente empregado em imagens de média resolução espacial (classificação supervisionada, a partir do algoritmo de máxima verossimilhança) complementado por uma posterior filtragem.

A limitação da área de influência direta e do entorno da obra mostrou-se promissora, pois tornou o processo mais ágil (arquivos menores resultam em processos manuais e automatizados mais rápidos) e garantiu precisão no processo de interpretação e classificação, na medida em que atenuou a possibilidade de confusão espectral.

Os processos com as ferramentas disponibilizadas por dois diferentes SIGs (Erdas e ArcGIS) garantiram qualidade e melhor controle no processo de generalização e filtragem das informações obtidas a partir das imagens de alta resolução, assim como a apresentação (*layout*) de saída dessas informações.

Para a imagem Ikonos 2, foi obtido um índice Kappa geral de 0,84, que a classifica como muito boa. Apenas a classe caracterizada como Pastagem apresentou concordância relativamente mais baixa (0,71) se comparada a outras classes. No entanto, essa ainda é considerada uma boa classificação.

A utilização de imagens de alta resolução padronizadas da forma aqui proposta juntamente com o algoritmo da máxima verossimilhança e a posterior filtragem mostraram-se eficientes como suporte para a avaliação da ocupação das terras tomadas pelas obras (área de influência direta) e do seu entorno.

Referências

Brites, R. S. **Verificação de exatidão em classificação de imagens digitais orbitais: efeito de diferentes estratégias de amostragem e avaliação de índices de exatidão**. 1996. 101 f. Tese (Doutorado em Ciências Florestais) – Universidade Federal de Viçosa, Viçosa, MG. Disponível em: <ftp://ftp.bbt.ufv.br/teses/ciencia_florestal/1996/111128f.pdf>. Acesso em: 17 ago. 2010.

ERDAS IMAGINE. **Erdas Field Guide**: manual Erdas Imagine 10. Atlanta: Erdas, 2010. Disponível em: <<http://www.erdas.com>>. Acesso em: 20 jul. 2010.

FISHER, J.; GOETZ, S. J. Considerations in the use of high spatial resolution imagery: an applications research assessment. In: AMERICAN SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING, 4., 2001, St. Louis. **Proceedings...** St. Louis: ASPRS, 2001. p.8.

FONSECA, L. M. G. **Processamento digital de imagens**. São José dos Campos: INPE, 2000.

GALPARSORO I. L. U.; FERNÁNDEZ, S. P. Medidas de concordancia: el índice Kappa. **Caderno de Atención Primaria**, v. 6, p. 169-171, 2001. Disponível em: <<http://www.fisterra.com/mbe/investiga/kappa/kappa2.pdf>>. Acesso em: 16 ago. 2010.

LEÃO, C.; KRUG, L. A.; KAMPEL, M.; FONSECA, L. M. G. Avaliação de métodos de classificação em imagens TM/Landsat e CCD/CBERS para mapeamento do uso e cobertura da terra na região costeira do extremo sul da Bahia. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** São José dos Campos: INPE, 2007. p. 939-946.

MASUOKA, P. M.; CLABORN, D. M.; ANDRE, R. G.; NIGRO, J.; GORDON, S. W.; KLEIN, T. A.; KIM, H. C. Use of IKONOS and LANDSAT for malaria control in the Republic of Korea. **Journal Remote Sensing of Environment**, v. 88, p. 187-194, 2003. Disponível em: <<http://mason.gmu.edu/~ocarras1/ikonos%20landsat%20malaria%20korea.pdf>>. Acesso em: 2 dez. 2010.

MENDONÇA, L. E. R. **Utilização de algoritmos de classificação em imagens IKONOS para mapeamento de feições terrestres: um estudo de caso.** 2006. 65 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG. Disponível em: <http://www.tede.ufv.br/tedesimplificado/tde_arquivos/4/TDE-2007-07-11T082051Z-41/Publico/texto%20completo.pdf>. Acesso em: 16 ago. 2010.

MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e Metodologia de Aplicação.** 1. ed. São José dos Campos: INPE, 2001. 250 p.

MOREIRA, A. A.; SOARES, V. P.; GLERIANI, J. M.; RIBEIRO, C. A. A. S. Utilização de algoritmos de classificação para o mapeamento do uso e cobertura da terra na bacia hidrográfica do Ribeirão São Bartolomeu, Viçosa, MG, a partir de uma imagem do sensor Ikonos II. In: SIMPÓSIO BRASILEIRO DE GEOGRAFIA FÍSICA APLICADA, 13., 2009. Viçosa, MG. **Anais eletrônicos.** Viçosa, MG: UFV, 2009. Disponível em: <http://www.geo.ufv.br/simposio/simposio/trabalhos_completos/>. Acesso em: 25 jun. 2010.

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

QUARTAROLI, C. F.; BATISTELLA, M. **Classificação digital de imagens de sensoriamento remoto: tutorial básico.** Campinas: Embrapa Monitoramento por Satélite, 2006. 50 p. (Documentos, 56).

RIBEIRO, R. M. P. **Avaliação de métodos de classificação de imagens IKONOS II para o mapeamento da cobertura terrestre.** 2003. 53 f. Dissertação (Mestrado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, MG.

RICHARDS, J. A. **Remote sensing digital image analysis: an introduction.** Berlin: Springer-Verlag, 1986. 281 p.

SUGUMARAN, R.; ZERR, D. Potential role of high-resolution satellite images in local government planning and management. In: AMERICAN SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING, 4., 2001, St. Louis. **Proceedings...** St. Louis: ASPRS, 2001. 7 p.



Monitoramento por Satélite

**Ministério da
Agricultura, Pecuária
e Abastecimento**

