

# Segmentação de imagens e classificação baseada em regras de conhecimento como novas abordagens para o mapeamento do uso da terra no Estado do Paraná.

Naïssa Batista da Luz  
Dalmar José dos Santos  
Alzir Felipe Buffara Antunes

Universidade Federal do Paraná - UFPR  
Caixa postal 19001 - 81531-990 - Curitiba - PR - Brazil  
{naïssa; felipe}@ufpr.br; dalmargeofoto@hotmail.com

**Abstract.** Land use mapping in the Paraná State, southern Brazil, is currently being held using Spot5 satellite imagery and data field, using traditional maximum likelihood and minimum distance classifiers. Unsatisfactory results have led to the development of research initiatives aiming to provide higher quality land use maps. Context knowledge based classification plays an important role in digital image analysis. The insertion of the knowledge base in the digital classification process is one of current forms used by the community of remote sensing for land cover mapping, in order to improve quality of the classification. Decision tree is one of the main algorithms for knowledge extraction and representation and was used in this research. Another technique showing very good results is the image segmentation prior to context classification. The image segmentation technique (FNEA: fractal net evolution approach) was used in this study to provide the context information and also associated with decision tree for knowledge extraction. The implemented algorithm was structured as a knowledge base used to classify the imagery. Different approaches of classification were assessed: conventional and contextual. Accuracy assessment index shows that knowledge base derived by means of decision tree algorithms could lead to promising results. Improvement in accuracy indexes were also obtained including segmented images, providing contextual information. The best results were obtained integrating both techniques.

**Keywords:** object oriented classification, context classification, multiresolution segmentation, decision trees

**Palavras-chave::** classificação orientada a objetos, classificação contextual, segmentação multiresolução, árvores de decisão

## 1. Introdução

O mapeamento do uso da terra no Estado do Paraná é atualmente obtido pela classificação supervisionada de imagens Spot5, apoiada por informações e pontos de apoio coletados em campo. Para a classificação das imagens, algoritmos tradicionais de máxima verossimilhança e de distância mínima vêm sendo empregados. As limitações destas técnicas de processamento de imagens refletem-se, no entanto, na qualidade dos resultados obtidos em termos de acurácia.

O emprego de novas abordagens e algoritmos de classificação de imagens surge, neste contexto, como uma possibilidade de obtenção de mapas mais apropriados à finalidade a que se destinam. Buscam-se resultados não só mais precisos como também mais representativos das formas e da topologia dos tipos de uso da terra, suscitando o desenvolvimento de uma metodologia que permita a obtenção destas informações. Os resultados aqui apresentados fazem parte de uma iniciativa de pesquisa que visa o desenvolvimento de uma metodologia capaz de integrar estas ferramentas, e de suprir a necessidade de mapas de uso da terra de melhor qualidade.

A disponibilidade de dados de média resolução e a adoção de um novo paradigma de processamento das imagens, baseado na segmentação e classificação de objetos têm sido responsáveis pela obtenção de resultados mais acurados. O desenvolvimento de algoritmos que se baseiam na forma de raciocínio e inteligência humanos, os chamados sistemas computacionalmente inteligentes, advindos da área de inteligência artificial, a exemplo das árvores de decisão, também trouxeram consigo grandes avanços na extração de informações a partir de imagens de sensoriamento remoto.

Um dos principais objetivos da inteligência artificial é o desenvolvimento de métodos e sistemas para a solução de problemas comumente solucionados pela mente humana, como por exemplo, o reconhecimento de imagens. Dentre as peças-chaves da inteligência estão a capacidade de aprendizado e de raciocínio, sendo que o conhecimento assume papel primordial, pois sem ele não ocorre aprendizado, e não há raciocínio. A representação do conhecimento envolve a transformação do conhecimento existente acerca de determinado problema para uma base de conhecimento em formato computacional (Kasabov, 1996). Por sua simplicidade e facilidade de geração e compreensão, as árvores de decisão e as regras de associação são as formas de representação simbólicas do conhecimento mais comumente utilizadas (Lin *et al.*, 2005). Uma árvore de decisão é uma representação gráfica para um procedimento de classificação, que se baseia no particionamento recursivo do espaço amostral (Michie *et al.*, 1994, Utgoff, 1999).

O sucesso na aplicação deste tipo de algoritmo de aprendizado deve-se a diversos fatores, que tornam as árvores de decisão especialmente atrativas. Em primeiro lugar, sua representação intuitiva faz com que o modelo resultante seja de fácil compreensão e assimilação (Breiman *et al.*, 1984; Friedl e Brodley, 1997; Martens *et al.*, 1998). O fato de serem algoritmos não-paramétricos (Gehrke *et al.*, 1998; Mciver e Friedl, 2002) permite não só a utilização mas também a integração de dados advindos de diversas fontes e com diferentes formas de distribuição estatística. Outro dos principais fatores relacionados à ampla adoção das árvores de decisão é certamente a capacidade de obtenção de bons resultados, os quais demonstram acurácia comparável ou superior a outros modelos de extração e representação do conhecimento e classificação de dados (Murthy, 1995; Hand, 1997; Mciver e Friedl, 2002). Por estas razões, esta é uma das abordagens que se pretende explorar neste trabalho, com potencial de incremento da acurácia e a melhoria na qualidade dos mapas de uso da terra.

A segunda das abordagens selecionadas envolve a divisão da imagem em objetos significativos do mundo real, da mesma forma que a visão humana, que tende a dividir a imagem em áreas homogêneas inicialmente, analisando posteriormente características das áreas com mais atenção. A segmentação da imagem permite que atributos dos objetos sejam derivados, auxiliando no entendimento da imagem (Blaschke *et al.*, 2000). Informações semânticas necessárias para a interpretação das imagens estão em grande parte representadas em objetos significativos e em suas relações mútuas e não em pixels individuais (Baatz e Schäpe, 1999).

A segmentação de uma imagem consiste na divisão ou separação da imagem em regiões de atributos similares ou de mesmas características (IEEE, 1990; Pratt, 2007). O procedimento pode permitir a obtenção de polígonos com aparência bastante natural, e um delineamento próximo ao que poderia ser gerado manualmente por um intérprete humano, o tornando bastante intuitivo e atrativo, ao contrário do padrão resultante da classificação dos pixels, o conhecido efeito “salt and pepper” (Blaschke *et al.*, 2000). De fato o padrão resultante da classificação dos pixels isolados é pouco agradável para um mapa de uso da terra, e traz consigo erros que por vezes não são facilmente detectados, sobretudo em áreas de limites entre objetos. Outra vantagem da abordagem é a grande quantidade de informações que pode ser derivada, como média, desvio padrão, e outros descritores espectrais, espaciais, de textura, da forma, do tamanho e do contexto dos objetos (Chubey *et al.*, 2006).

A segmentação multi-resolução foi utilizada em conjunto com a classificação baseada no conhecimento (*knowledge based classification*), para a detecção da vegetação por Chen (2005), resultando na obtenção de valores de acurácia total de 88%, quase 10% superiores à média anteriormente obtida e também na estimativa da altura de árvores individuais. O conhecimento é representado por regras de decisão, como as que podem ser obtidas pela indução de árvores de decisão.

## **2. Metodologia**

### **2.1. Materiais utilizados**

Imagens do satélite Spot5 do ano de 2005 foram disponibilizadas para a realização dos experimentos. Foi selecionada uma cena imageando áreas com relatórios de campo disponíveis, que descrevem os tipos de uso da terra e contém pontos de controle coletados com GPS diferencial. A área de estudo foi também selecionada pela disponibilidade do modelo numérico do terreno, prevendo-se a ortoretificação da cena. Os experimentos foram realizados com as bandas multiespectrais do verde, vermelho, infra-vermelho próximo e infra-vermelho médio, com resolução espacial de 10m.

O recorte de imagem selecionado inclui áreas pertencentes aos municípios de Guaraci, Jaguapitã, Munhoz de Melo, Miraselva, Astorga, Pitangueiras e Prado Ferreira, localizados na porção norte do Estado do Paraná, próximo à divisa com o Estado de São Paulo.

Foram utilizados aplicativos disponíveis no Laboratório de Sensoriamento Remoto do Curso de Pós-graduação em Ciências Geodésicas da Universidade Federal do Paraná, para o processamento das imagens, tais como Envi (RSI); Erdas (Leica Geosystems); Matlab (The Mathworks Inc.); e-Cognition (Definiens Inc.) e ArcGis (Esri). O aplicativo de domínio público Weka, desenvolvido pela Universidade de Waikato, Nova Zelândia, e disponível na *internet* também foi utilizado (Weka, 2008). Também foram desenvolvidos dois aplicativos, o primeiro para a conversão do formato de arquivo *.roi* de amostras de treinamento do envi para o formato do Weka, *.arff*. O segundo foi desenvolvido para a geração de regras no formato IF-THEN para serem utilizadas em ambiente do aplicativo Matlab, a partir das regras obtidas pela indução de árvores de decisão no Weka.

### **2.2. Segmentação das imagens**

Testes de segmentação foram realizados, alterando-se consecutivamente os parâmetros de escala e o critério de homogeneidade, que define a relação cor/forma e a relação compacidade/suavidade dos objetos. A cada segmentação um dos parâmetros sofreu alterações com incrementos sucessivos, mantendo-se os demais parâmetros constantes. Desta forma, foi analisada a influência de cada parâmetro isoladamente. Os testes de segmentação foram planejados para a definição do parâmetro de escala, inicialmente, por ser considerado o que mais influi no tamanho dos objetos. A meta foi a obtenção de objetos significativos com relação às classes de uso da terra que se deseja representar e à escala de trabalho de interesse (1:100.000).

Ao conjunto de dados de entrada foi atribuído peso 1 para todas as camadas de informação, de forma que os pesos não interfiram nos resultados da segmentação enquanto os parâmetros estiverem sendo testados individualmente. O parâmetro de escala sofreu incrementos sucessivos em passos de 10 unidades, iniciando-se em 10 e encerrando-se em 210, quando ficou claro que valores superiores resultariam em objetos muito grandes e heterogêneos, englobando por vezes mais do que um tipo de uso da terra.

Com uma análise visual dos resultados obtidos com a variação do parâmetro de escala, foi possível selecionar um conjunto menor de valores a serem adotados para os testes com os demais parâmetros. Aumentando-se a taxa de variação do parâmetro de escala, o parâmetro de forma/cor será testado da mesma forma, variando-se os valores a cada segmentação. A definição dos parâmetros mais apropriados à representação dos objetos na escala de interesse de acordo com a legenda definida se deu através da análise visual. Foram considerados alguns critérios gerais, como a qualidade do delineamento de diversos tipos de cobertura do solo (como a separação entre diferentes tipologias florestais e entre agricultura e pasto, por exemplo), a segmentação de objetos lineares, a ocorrência de falhas na segmentação e a descrição da qualidade da segmentação de forma geral, de acordo com método proposto por Neubert *et al.* (2006) e Herold *et al.* (2007).

### 2.3. Geração dos descritores dos objetos

A partir das imagens segmentadas, descritores dos objetos foram calculados, também no aplicativo e-Cognition. Foram gerados 24 descritores, exportados para o formato *shapefile* (.shp). Estes arquivos foram convertidos, no aplicativo ArcMap, para o formato *raster (grid)*. Importados para o Envi, os descritores foram adicionados às quatro bandas originais (verde, vermelho, infra-vermelho próximo e infra-vermelho médio) e ao índice de vegetação de diferença normalizada, totalizando 29 imagens.

Foram calculados os descritores: desvio padrão, valor mínimo e valor médio dos pixels dos objetos para cada uma das 4 bandas originais, brilho, índice de forma, área, largura, comprimento, relação comprimento / largura, ajuste à forma retangular, ajuste à forma elíptica, densidade, compacidade, comprimento de borda e assimetria. Uma revisão a respeito da formulação destes descritores pode ser encontrada em Baatz *et al.* (2000).

### 2.4. Seleção das amostras

Tanto para a classificação das imagens quanto para a indução das árvores de decisão faz-se necessária a seleção de amostras de treinamento. O Envi foi utilizado para a seleção de amostras contendo algo entre 100 e 150 pixels, a princípio. Após a exclusão de discrepâncias, amostras com 300 a 350 pixels foram geradas. As amostras de verificação têm quantidades de pixels proporcionais à sua ocorrência na imagem, coletando-se entre 3000 e 200.000 pixels dependendo da classe.

As classes definidas foram: floresta em estágio avançado de desenvolvimento, floresta em estágio médio de desenvolvimento, florestas plantadas com espécies exóticas, áreas de formação pioneira de influência fluvial, áreas agrícolas e pastagens, solos expostos, áreas urbanas e corpos d'água. A classe de áreas agrícolas e pastagens foi ainda subdividida em tipos I, II e III durante o processo de classificação das imagens, e também para a estimativa da acurácia da classificação, sendo unida somente com a finalidade de apresentação do mapa de uso da terra. Os arquivos exportados em formato *ascii* extensão *.txt* foram lidos em um aplicativo escrito em ambiente Matlab e convertidos para o formato do Weka, extensão *arff*.

### 2.4. Indução de árvores de decisão

A indução das árvores de decisão é um processo bastante simples, no qual são utilizados os valores dos dados de entrada amostrados para a seleção dos atributos que formam cada nó da árvore e definição dos limites para a divisão recursiva do espaço amostral, formando os galhos da árvore e as folhas que contém as classes ao final do processo. O algoritmo implementado no Weka denomina-se J48, e é uma adaptação do algoritmo C4.5 proposto por Quinlan (1986).

A grande quantidade de descritores que pode ser gerada faz com que haja redundância e irrelevância de atributos. A importância de sua seleção, neste caso, reside no fato de que o desempenho de muitos esquemas de classificação pode ser deteriorado com a adição de atributos inúteis (WITTEN e FRANK, 2005). Segundo WITTEN e FRANK (2005), as árvores de decisão têm boa capacidade de seleção de atributos, optando-se por realizar a seleção de atributos antes da indução da árvore de decisão voltada à classificação da imagem. Os atributos mais relevantes à classificação, selecionados numa primeira etapa de indução de árvores de decisão, foram utilizados na segunda etapa, quando as regras de conhecimento para a classificação das imagens são geradas.

As regras exportadas do WEKA em arquivos de texto foram convertidas, com o auxílio de um aplicativo desenvolvido em linguagem C, que permite a obtenção de regras do tipo IF-THEN, compatíveis com a linguagem do ambiente de programação Matlab. O arquivo de

texto contendo estas regras foi utilizado como um aplicativo de classificação das imagens baseada em regras de conhecimento.

## 2.5. Classificação das imagens

Além do algoritmo para a classificação das imagens baseado em regras de conhecimento, foram realizadas classificações com os algoritmos de distância mínima e de máxima verossimilhança, atualmente empregados no mapeamento do uso do solo no Estado do Paraná. Foram elaborados dois conjuntos de dados de entrada, a partir dos quais foram amostrados os valores dos atributos utilizados nas classificações.

O primeiro conjunto é composto pelas imagens originais das bandas do verde, vermelho, infravermelho próximo e infravermelho médio, além do índice de vegetação de diferença normalizada. O segundo conjunto de dados de entrada é composto pelos atributos selecionados na primeira etapa de indução de árvores de decisão, a partir do conjunto de dados de entrada composto pelas mesmas imagens do primeiro conjunto e pelos descritores dos objetos, formado pelas 29 imagens anteriormente mencionadas. Para ambos os conjuntos de dados de entrada, foram realizadas três classificações, para cada um dos algoritmos citados, totalizando seis delas.

## 3. Resultados e Discussão

A indução das árvores de decisão para a seleção dos atributos relevantes à classificação resultou na seleção de 6 imagens, incluindo as bandas originais do vermelho e do infravermelho médio, e as imagens resultantes do cálculo dos descritores do desvio padrão para a banda do infravermelho próximo, mínimo da banda do verde, o brilho e a largura dos objetos. Os resultados da aplicação dos algoritmos de classificação a este conjunto de dados de entrada, denominado conjunto 2 e ao conjunto 1, formado pelas bandas originais e pelo índice de vegetação, são apresentados na Tabela 1.

**Tabela 1.** Valores da acurácia global das classificações para os três algoritmos testados e para os dois conjuntos de dados.

Dados de entrada	Distância Mínima	Máxima Verossimilhança	Regras de conhecimento
Conjunto 1	53.28%	66.19%	64.49%
Conjunto 2	61.75%	70.02%	71.87%

Observa-se na Tabela 1 incremento nos valores da acurácia da classificação quando o algoritmo para indução de árvores de decisão J48 foi utilizado, apenas para o segundo conjunto de dados. No caso do primeiro conjunto de dados, o melhor resultado foi obtido aplicando-se a classificação baseada nas regras geradas pela indução da árvore de decisão.

Percebe-se também nesta tabela que de forma geral, houve um incremento na acurácia dos resultados quando as imagens obtidas pelo cálculo dos descritores dos objetos segmentados foram incluídas na classificação. Esperava-se este resultado já que são bastante evidentes os benefícios da segmentação prévia das imagens e posterior classificação dos objetos.

Os resultados da acurácia por classe de uso da terra das classificações mais acuradas são apresentados na Tabela 2, para o algoritmo da máxima verossimilhança e na Tabela 3 para o algoritmo que utiliza as regras de conhecimento geradas pela indução da árvore de decisão. A comparação da Tabela 2 com a Tabela 3 revela que ainda que nem todos os valores de acurácia por classe sejam maiores, a maioria o é, e também que para quase totalidade das classes de uso da terra valores de confusão (localizados fora da diagonal principal) menores foram obtidos quando as regras de conhecimento foram aplicadas. Estes resultados podem ser observados visualmente analisando a Figura 1.

**Tabela 2.** Acurácia por classe obtida na classificação do segundo conjunto de dados com o algoritmo de máxima verossimilhança. Os números na primeira linha representam as classes de uso da terra das amostras de verificação e os da primeira coluna as classes do mapa de uso da terra gerado.

Classe	1	2	3	4	5	6	7	8	9	10
<b>1</b>	<b>64.19</b>	11.75	31.49	-	-	0.03	-	-	-	-
<b>2</b>	32.10	<b>73.87</b>	0.42	1.01	-	1.97	0.03	-	0.60	-
<b>3</b>	-	0.01	<b>58.19</b>	-	-	-	-	-	-	4.00
<b>4</b>	0.04	4.86	0.67	<b>75.80</b>	12.82	2.35	5.20	-	6.89	0.04
<b>5</b>	0.01	0.24	0.03	0.51	<b>67.52</b>	3.10	0.06	4.97	-	0.29
<b>6</b>	2.14	0.33	-	0.38	6.80	<b>80.05</b>	1.60	-	-	-
<b>7</b>	-	-	-	0.09	3.00	1.46	<b>42.60</b>	2.68	-	-
<b>8</b>	-	-	-	0.37	7.86	3.26	23.56	<b>88.83</b>	3.06	0.04
<b>9</b>	-	0.11	1.60	9.77	1.99	7.67	26.39	3.52	<b>88.68</b>	16.40
<b>10</b>	1.52	8.83	7.60	12.08	0.01	0.10	0.56	-	0.77	<b>79.24</b>

1 - floresta em estágio avançado de desenvolvimento; 2 - floresta em estágio médio de desenvolvimento; 3 - florestas plantadas com espécies exóticas; 4 - áreas de formação pioneira de influência fluvial; áreas agrícolas e pastagens 5 - tipo I; 6 - tipo II; 7 - tipo III; 8 - solos expostos; 9 - áreas urbanas; 10 - corpos d'água



**Tabela 3.** Acurácia por classe obtida na classificação do segundo conjunto de dados com o algoritmo de máxima verossimilhança. Os números na primeira linha representam as classes de uso da terra das amostras de verificação e os da primeira coluna as classes do mapa de uso da terra gerado.

Classe	1	2	3	4	5	6	7	8	9	10
<b>1</b>	<b>70.10</b>	8.31	11.96	-	-	0.45	-	-	-	-
<b>2</b>	28.44	<b>72.02</b>	0.78	0.54	-	5.38	-	-	0.93	-
<b>3</b>	0.02	8.59	<b>82.07</b>	3.06	-	-	-	-	-	14.65
<b>4</b>	-	1.45	0.40	<b>70.79</b>	6.60	0.27	16.18	0.01	16.66	1.11
<b>5</b>	1.39	9.05	4.43	10.45	<b>83.19</b>	27.58	9.45	4.57	4.00	1.54
<b>6</b>	0.05	0.52	-	0.11	3.41	<b>63.58</b>	2.73	-	0.24	-
<b>7</b>	-	-	-	1.04	2.77	2.08	<b>59.78</b>	9.59	0.27	-
<b>8</b>	-	-	-	-	3.80	0.07	3.54	<b>78.25</b>	0.13	-
<b>9</b>	-	0.01	-	6.47	0.23	0.58	8.30	7.59	<b>77.73</b>	0.07
<b>10</b>	-	0.05	0.36	7.53	-	-	0.02	-	0.03	<b>82.63</b>



1 - floresta em estágio avançado de desenvolvimento; 2 - floresta em estágio médio de desenvolvimento; 3 - florestas plantadas com espécies exóticas; 4 - áreas de formação pioneira de influência fluvial; áreas agrícolas e pastagens 5 - tipo I; 6 - tipo II; 7 - tipo III; 8 - solos expostos; 9 - áreas urbanas; 10 - corpos d'água

As características dos mapas de uso da terra obtidos com a inclusão de imagens segmentadas na classificação podem ser observadas na Figura 1. A redução de efeito “salt and pepper” e a maior definição nas bordas dos objetos são vantagens adicionais da adoção desta abordagem que podem ser visualizadas na figura, comparando-se os pares de resultados obtidos com a aplicação de cada algoritmo. Ao lado direito da figura foram posicionados os recortes obtidos pela aplicação do algoritmo de regras de conhecimento. Apesar de valores próximos de acurácia média global terem sido obtidos entre as classificações com o algoritmo de máxima verossimilhança (70,02%) e o de regras de conhecimento (71,87%), percebe-se que uma menor confusão entre as classes resultou da aplicação do segundo algoritmo. Esta é uma tendência dos resultados obtidos da aplicação de regras geradas pela indução de árvores de decisão, já que este algoritmo não utiliza medidas de tendências ou estatísticas de classe para a definição dos limites do espaço amostral, e sim medidas de ganho de informação para a seleção dos atributos e dos valores de particionamento (Breiman *et al*, 1984; Friedl e Brodley, 1997).



Classificações resultantes da aplicação do algoritmo de distância mínima, para os conjuntos de dados de entrada 1 e 2, em (a) e (b), respectivamente.




Classificações resultantes da aplicação do algoritmo de máxima verossimilhança, para os conjuntos de dados de entrada 1 e 2, em (c) e (d), respectivamente.











Classificações resultantes da aplicação do algoritmo de árvore de decisão, para os conjuntos de dados de entrada 1 e 2, em (e) e (f), respectivamente.



Porção da imagem do satélite Spot 5 em composição colorida, com a banda 3 (infravermelho próximo) no canal R, banda 4 (infravermelho médio) no canal G e banda 2 (vermelho) no canal B.



Legenda da classificação	
	Florestas em estágio avançado de desenvolvimento
	Florestas em estágio inicial ou médio de desenvolvimento
	Formações pioneiras de influência fluvial
	Florestas plantadas
	Áreas agrícolas e pastagens
	Solos expostos
	Áreas urbanas
	Corpos d'água

**Figura 1.** Resultados obtidos com a aplicação dos diferentes algoritmos e conjuntos de dados de entrada utilizados neste trabalho, conforme indicado, e porção semelhante da imagem original do satélite Spot5 em composição colorida.

#### 4. Conclusões

Os resultados obtidos com os experimentos realizados indicam, a princípio, que:

- a abordagem de classificação orientada a objetos, que se inicia com a segmentação da imagem, permitiu o incremento na acurácia global da classificação para qualquer um dos algoritmos utilizados;
- a segmentação da imagem auxilia também na melhoria da acurácia por classe, na redução do efeito “salt and pepper” e na melhor definição das bordas dos objetos;
- o algoritmo implementado com as regras de conhecimento geradas pela indução das árvores de decisão não permitiu aumento da acurácia global média com relação aos resultados obtidos com os algoritmos tradicionais, quando o primeiro conjunto de dados foi utilizado, diferente do que aconteceu com a utilização do segundo e mais complexo conjunto de dados;

- apesar dos valores de acurácia global mais baixos, a avaliação da acurácia por classes revela resultados em muitos casos superiores quando as regras de conhecimento são utilizadas, com menores valores de confusão entre classes.

Finalmente, pode-se dizer que ambas as abordagens foram consideradas promissoras e estes resultados apontam a viabilidade de prosseguir neste caminho, unindo técnicas promissoras na extração de informações de imagens Spot5.

## Referências

- Baatz, M.; Heynen, M.; Hofmann, P.; Lingenfelder, I.; Mimler, M.; Schäpe, A.; Weber, M.; Willhauck, G. **eCognition User Guide**. München: Definiens AG, 2000.
- Baatz, M.; Schäpe, A. Object-Oriented and Multi-Scale Image Analysis in Semantic Networks. In: PROCEEDINGS OF THE 2ND INTERNATIONAL SYMPOSIUM ON OPERATIONALIZATION OF REMOTE SENSING, 2., 1999, Enschede. **Proceedings...** Enschede: International Institute for Geo-Information Science and Earth Observation – ITC, 1999.
- Blaschke, T.; Lang, S.; Lorup, E.; Strobl, J.; Zeil, P.: Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications. In: Cremers, A. & Greve, K. (Eds.): **Umweltinformation für Planung, Politik und Öffentlichkeit** / Environmental Information for Planning, Politics and the Public, Marburg: Metropolis - Verlag, v. 2: p. 555-570, 2000.
- Breiman, L.; Friedman, J. H.; Olshen, R. A.; Stone, C. J. **Classification and regression trees**. Boca Raton: Chapman & Hall, p. 386, 1984.
- Chen, L., Chiang, T.; Teo, T. Fusion of LIDAR Data and High Resolution Images for Forest Canopy Modelling. In: PROCEEDINGS OF THE 26TH ASIAN CONFERENCE ON REMOTE SENSING, 26., 2005, Hanoi. **Proceedings...** Hanoi: Asian Association on Remote Sensing, 2005.
- Chubey, M.; Franklin, S.; Wulder, M. Object-based analysis of ikonos-2 imagery for extraction of forest inventory parameters. **Photogrammetric Engineering & Remote Sensing**, v. 72, n. 4, p. 383 - 394, 2006.
- Friedl, M. A.; Brodley, C. E. Decision Tree Classification of Land Cover from Remotely Sensed Data. **Remote Sensing of Environment**, New York, v. 61, n. 3, p. 399 - 409, 1997.
- Gehrke, J.; Ramakrishnan, R.; Ganti, V. Rainforest - a framework for fast decision tree construction of large datasets. In: PROCEEDINGS OF THE 24TH INTERNATIONAL CONFERENCE ON VERY LARGE DATABASES, 24., 1998, New York, **Proceedings...** New York: Morgan Kaufmann, p. 416-427. 1998.
- Hand, D.; Mannila, H.; Smyth, P. (Eds.). **Principles of Data Mining**. Cambridge, MA: MIT, 546 p., 2001.
- Herold, H.; Neubert, M.; Meinel, G. Avaliação quantitativa da segmentação de imagens de sensoriamento remoto - conceitos e mais resultados. In: ANAIS XIII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. Anais... INPE, p. 5823 - 5825, 2007.
- IEEE - Institute of Electrical and Electronics Engineers. **IEEE standard glossary of image processing and pattern recognition terminology**. New York: IEEE, IEEE Standard 610, 4. 1990.
- Kasabov, N. K. **Foundations of neural networks, fuzzy systems, and knowledge engineering**. A Bradford Book. Cambridge, MA: MIT, 552 p., 1996.
- Lin, T. Y.; Ohsuga, S.; Liau, C. J.; Hu, X. (Eds.). **Foundations and novel approaches in data mining**, New York: Springer-Verlag, 376 p., 2005.
- Martens, J.; Wets, G.; Vanthienen, J.; Mues, C. An initial comparison of a fuzzy neural classifier and a decision tree based classifier. **Expert Systems with Applications**, v. 15, n. 3, p. 375-381. 1998.
- Mciver, D.K.; Friedl, M.A. Using prior probabilities in decision-tree classification of remotely sensed data. **Remote Sensing of Environment**, v.81, n.2, p. 253 - 261. 2002.
- Michie, D.; Spiefelhalter, D. J.; Taylor, C. C. (Eds.) **Machine Learning, Neural and Statistical Classification**. New York: Ellis Horwood, 290 p., 1994.
- Murthy, S. K. **On growing better decision trees from data**. 288 p. Tese (Doutorado em Ciência da Computação) - Department of Computer Science, Johns Hopkins University, Baltimore, Maryland, 1995.
- Neubert, M., Herold, H., Meinel, G. Evaluation of remote sensing image segmentation quality – further results and concepts. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XXXVI, n.4/C42, Salzburg, Austria, 2006.
- Pratt, W. **Digital image processing: PIKS scientific inside**. 4.ed. New York: J. Wiley, 786 p., 2007.
- Quinlan, J. R. Induction of decision trees. **Machine Learning**, v. 1, n. 1, p.81-106, 1986.
- Utgoff, P. Decision Trees. In: Wilson, R. A.; Keil, F. C. (Eds). **The MIT encyclopedia of the cognitive sciences**, Massachusetts: MIT Press, 1104 p., 1999.
- Weka 3; Data Mining Software in Java. Disponível em: <<http://www.cs.waikato.ac.nz/ml/weka/>> Acesso em: 16 de novembro de 2008.
- Witten, I.H., Frank, E. (Eds.). **Data Mining: practical machine learning tools and techniques**, 2 ed., San Francisco: Morgan Kaufmann, 2005.