

## **Incorporação de conhecimento do especialista através de regras para a classificação de imagens de sensores remotos de alta resolução.**

Thiago Broerman Cazes<sup>1</sup>  
Raul Queiroz Feitosa<sup>1,2</sup>  
Luiz Felipe Guanaes Rego<sup>1</sup>

<sup>1</sup> Pontifícia Universidade Católica do Rio de Janeiro – PUC-RIO  
Rua Marquês de São Vicente 225, Gávea, Rio de Janeiro, CEP 22453-900, RJ, Brasil  
{tcazes,raul}@ele.puc-rio.br  
regoluiz@rdc.puc-rio.br

<sup>2</sup> Universidade do Estado do Rio de Janeiro - UERJ  
Rua São Francisco Xavier 524, Maracanã, Rio de Janeiro, CEP 20550-900, RJ, Brasil

**Abstract.** New high resolution satellites for commercial purposes became available in the few years. This increases the need of new automatic knowledge based image interpretation methods. The present work falls into this context and proposes an automatic classification model for high resolution remotely sensed images. The model consists of two stages. In the first stage only spectral information are used for classification. In the second stage GIS (geographic information system) data are combined with the result of the spectral analysis by means of fuzzy rules. To validate the proposed model experiments were performed based on IKONOS images from 2001 and 2002 of the Pedra Branca Park, which is an important Atlantic Forest fragment in the State Rio de Janeiro in Southeast Brazil.

**Palavras-chave:** Sensoriamento Remoto, Classificação Automática, Regras Fuzzy, Neuro Fuzzy

### **1. Introdução**

Uma das aplicações mais importantes das imagens obtidas por sensores remotos são atividades de planejamento ligadas a preservação ambiental como monitoramento de queimadas, acompanhamento de áreas de risco e planejamento de expansão urbana sobre áreas de florestas. Nesse contexto tem crescido o interesse mundial por métodos ou sistemas baseados no conhecimento voltados para classificação de imagens de sensores remotos, em especial de imagens de alta resolução (Bückner et al. 2001, Liedtke et al. 1999, Liedtke et al. 1997, Niemann et al. 1990, Matsuyama et al. 1990 e Mckeown et al 1985). Esses sistemas buscam reproduzir em um ambiente computacional o raciocínio, muitas vezes subjetivo, do foto-interprete. Ainda não existem métodos que consigam realizar toda a tarefa de interpretação independente da interação do ser humano, ou seja, completamente automáticos.

O presente trabalho vem se inserindo nessa linha de pesquisa propondo um método de incorporação do conhecimento subjetivo do foto-interprete em um procedimento clássico de classificação supervisionada automática baseada em objetos de imagens de sensores remotos de alta resolução.

Os sistemas neuro-fuzzy por sua vez baseiam-se em conceitos da lógica fuzzy e redes neurais artificiais. Através da incorporação dos conjuntos fuzzy esse tipo de sistema permite a representação do conhecimento expresso de maneira imprecisa o especialista, por outro lado são capazes de prover o aprendizado através de dados de treinamento presentes nas redes neurais artificiais.

Para avaliar o procedimento proposto foi escolhida como sítio alvo uma área representativa da Mata Atlântica no Estado do Rio de Janeiro. Inúmeras são as razões que justificam esta escolha. Primeiramente a Mata Atlântica é o bioma brasileiro mais devastado. Inicialmente esta mata ocupava a região costeira do país do Ceará ao Rio Grande do Sul em

área aproximada de 1.000.000 km<sup>2</sup>. Atualmente está restrita a manchas distribuídas por vários Estados, ocupando área aproximada de 91.000 km<sup>2</sup> (Thomas et al. 1998, SIPS 1999).

Na segunda seção desse trabalho será apresentada os sistemas neuro-fuzzy voltados para classificação utilizados, na terceira seção a metodologia de classificação desenvolvida na quarta seção serão apresentados os detalhes relativos a implementação e os procedimentos experimentais executados. Na quinta seção serão apresentados os resultados obtidos.

## 2. Sistemas Neuro-Fuzzy

A lógica fuzzy permite a expressão de forma clara e simples da incerteza e imprecisão inerentes às avaliações de um especialista, cuja experiência se deseja modelar num sistema de classificação baseado em conhecimento. Em outras palavras, a lógica fuzzy pode ser vista como uma maneira de expressar incerteza (Elkan et al. 1994). A lógica fuzzy permite representar valores de pertinência (grau de verdade) intermediários entre os valores de verdadeiro e falso da lógica clássica (bivalente).

As variáveis de entrada em um sistema fuzzy são mapeadas em conjuntos fuzzy por meio de funções de pertinência. O mapeamento de uma entrada em um conjunto fuzzy gera um grau de pertinência dessa entrada ao conjunto. Por meio de regras SE-ENTÃO o sistema é capaz de expressar condições de pertinência. Tais regras são formuladas da seguinte forma: SE (ANTECEDENTES) ENTÃO (CONSEQUENTE). Nessa formulação os ANTECEDENTES expressam as condições a serem satisfeitas que resultam em um desdobramento representado pelo CONSEQUENTE da regra.

Porém o grande problema dos sistemas baseados em regras está na quantidade de parâmetros a serem ajustados funcionamento adequado do modelo. Esses parâmetros livres se encontram na formação das funções de pertinência dos antecedentes e dos consequentes. Em outras palavras para se criar uma regra nebulosa do tipo SE ALGO FOR ALTO ENTÃO A SAÍDA É BAIXA precisa definir-se que tipo de função e ajustar os parâmetros que indicam o que é ALTO e BAIXO no contexto das regras. Esse procedimento de ajuste não é trivial.

Os sistemas adaptativos neuro-fuzzy unem a flexibilidade dos sistemas fuzzy, provida pelas regras, com a arquitetura de Redes Neurais que propicia o aprendizado adaptativo através de dados de treinamento, ajustando adaptativamente os parâmetros das funções de pertinência. Mais especificamente a arquitetura ANFIS (*adaptive-network-based fuzzy inference system*) apresentado por Jang (1993) prove aprendizado por meio de dados de treinamento por um algoritmo híbrido, usando retropropagação do erro em conjunto com um método dos mínimos quadráticos.

Os sistemas ANFIS possuem uma arquitetura em rede similar a arquitetura das redes neurais artificiais, que mapeiam um conjunto de entradas em uma saída. Esse mapeamento é feito através de uma série de cinco camadas intermediárias. Cada camada intermediária tem um papel específico relacionado com o processo de inferência fuzzy. A primeira camada é responsável pelo mapeamento da entrada nos conjuntos fuzzy gerando os antecedentes das regras; na segunda camada são realizadas as operações t-norm que possibilita a criação de regras com múltiplos antecedentes; na terceira camada é realizada apenas uma operação de normalização; na quarta camada os consequentes são gerados conforme o modelo linear desenvolvido por tipo Takagi-Sugeno apresentadas em Takagi et al. (1985). Na última camada é realizada uma operação T-conorm, que possibilita a agregação de múltiplos consequentes para uma única saída do sistema.

Os sistemas ANFIS computam os parâmetros das funções de pertinência fuzzy interativamente durante a fase de treinamento calculando a resposta obtida pelo sistema e a resposta esperada. E então pelo erro quadrático entre essas respostas o sistema automaticamente se adapta modificando os parâmetros das funções de pertinência fuzzy

relacionadas com os antecedentes e os conseqüentes obtendo assim uma nova resposta para o sistema. Esse procedimento é executado com os dados de treinamento até que não se tenha mais diminuição significativa do erro relativo à saída esperada.

### **3. Metodologia de classificação**

Métodos convencionais de classificação supervisionada baseados na resposta espectral pura e simples, ou mesmo quando se utilizam atributos de textura, não apresentam desempenho satisfatório em imagens de alta resolução. A incorporação de outros atributos se torna necessária para a obtenção de classes mais complexas e com isso mapas de cobertura de solo mais elaborados. Em um procedimento clássico de classificação supervisionada a inclusão de atributos causa um aumento de complexidade no processo. O aumento dessa complexidade por sua vez causa uma dificuldade desses procedimentos convergirem para um desempenho aceitável. Em linhas gerais pode-se dizer que o aumento do número de atributos, traz mais informação para o procedimento, porém não necessariamente melhora o desempenho geral da classificação.

Para evitar o problema do aumento explosivo da complexidade dos classificadores supervisionados, o trabalho baseia-se em uma metodologia híbrida que utiliza na primeiramente um classificador supervisionado baseado somente em dados espectrais e em seguida introduz atributos espaciais, dados de GIS e altimetria para identificação mais precisa das classes por meio de regras fuzzy elaboradas por especialistas.

É importante salientar que o modelo proposto envolve a classificação baseada em objetos. Nesse aspecto um procedimento inicial de segmentação é realizado conforme o diagrama da Erro! A origem da referência não foi encontrada.. Inúmeros trabalhos vêm mostrando as vantagens de procedimentos baseados em objetos para interpretação de imagens de sensores remotos de alta resolução (Blaschke et al. 2001, Rego et al. 2003)

#### **3.1. Fase 1: Classificação supervisionada**

Nessa fase são utilizados classificadores supervisionados clássicos, nesse trabalho somente os atributos espectrais foram levados em consideração. Em linhas gerais um atributo espectral representa a média da resposta espectral em cada banda de cada objeto da imagem.

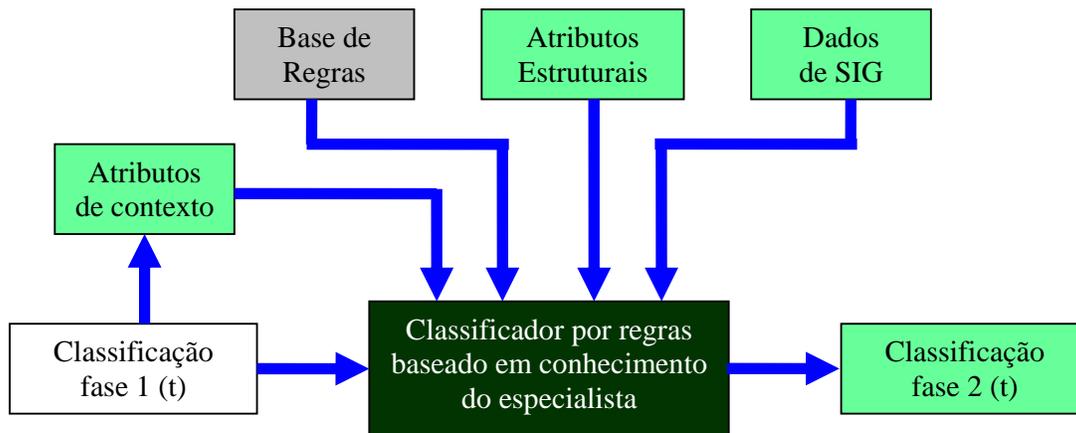
A classificação produz para cada objeto um vetor com os graus de pertinência a cada uma das classes da legenda. Esse vetor é utilizado como entrada no procedimento de classificação da Fase 2.

#### **3.2. Fase 2: Classificação baseada em regras**

A classificação baseada em regras se baseia em três principais componentes. O primeiro é o sistema de inferência que conforme foi definido na seção 2. O segundo componente são as regras e o terceiro os dados propriamente ditos conforme apresentado na **Figura 1**.

A base de regras é definida pelo especialista, por exemplo, durante um procedimento de classificação manual efetuando a definição das chaves de classificação. Essa base tem a finalidade de expressar o mais fielmente e de forma objetiva o raciocínio humano usado durante o procedimento de classificação manual.

Os dados utilizados pelos sistemas de inferência e pelas regras fuzzy constituem uma série de atributos relacionados com os segmentos a serem classificados. Esses atributos podem aparecer de inúmeras fontes como, por exemplo: dados de GIS, atributos de contexto e vizinhança, dados espaciais relativos a forma dos segmentos e das suas bordas e dados de altimetria. Em princípio qualquer atributo mensurável do objeto pode ser utilizado para elaboração das regras.



**Figura 1 - Detalhe do modelo de classificação da Fase 2**

## 4. Avaliação experimental

### 4.1. Dados utilizados

Foram utilizadas imagens de sensores remotos de alta resolução, obtidas em junho de 1999 e março de 2001 de uma área de aproximadamente 13 Km<sup>2</sup>. Essa área cobre uma grande parcela do Parque Estadual da Pedra Branca e também a sua vizinhança, composta de áreas urbanas e industriais. Os dados selecionados compreendem duas imagens IKONOS do ano de 2001 e 2002 do sensor multiespectral, ou seja, com quatro bandas espectrais: vermelho, azul, verde e infravermelho. Essas imagens têm resolução espacial de 4m. As imagens utilizadas têm uma resolução radiométrica de 11 bits em cada banda espectral.

Além dessas imagens as classificações de referencia elaborada pelo especialista estava disponível tanto para imagem de 2001 quanto para a de 2002.

### 4.2. Procedimento de segmentação

A segmentação usada nesse trabalho leva em conta somente as informações espectrais. O algoritmo utilizado para a segmentação nesse trabalho é do tipo crescimento de regiões, conforme implementado no software e-Cognition 4.0 (DEFINIENS, 2004). Foi utilizado então parâmetro de escala igual a 90 e fatores de cor/forma de 0.2 e suavidade/compactação de 0.5.

### 4.3. Fase 1: Classificação supervisionada

Para analisar a influência do procedimento de classificação supervisionada dois procedimentos amplamente utilizados atualmente foram selecionados. Primeiramente um procedimento com base estatística na teoria de discriminantes quadráticos que assume uma distribuição normal multivariada dos atributos analisados, e então se estima a matriz de variância e covariância estimada por grupo que minimiza o erro médio quadrático nos padrões de treinamento.

Por outro lado as redes MLPs consistem de um conjunto de unidades sensoriais, ou neurônios arrumados de forma de camadas Tem-se uma camada de entrada com nós não computacionais, uma ou mais camadas ocultas com nós computacionais não lineares e ainda uma camada de saída com nós também computacionais. Ligando um no a outro tem-se os

pesos, chamados de pesos simpáticos. Esses pesos são modificados durante a fase de treinamento usando o algoritmo de retropropagação do erro que tem como objetivo minimizar o erro médio quadrático. Esse procedimento pode ser encontrado com mais detalhes de implementação em Haykin (2001).

#### 4.4. Elaboração da base de regras

A base de regras foi elaborada com o auxílio do foto interprete. As regras foram elaboradas com o objetivo de aumentar a acurácia obtida durante a Fase 1 do modelo proposto. Nesse sentido foi analisada a classificação resultante da fase 1 classe a classe, verificando os erros encontrados e mapeando as principais confusões espectrais que acontecem.

As três principais confusões espectrais foram apresentadas a um especialista em classificação de imagens cuja tarefa era elaborar um conjunto de regras com base nos atributos disponíveis capazes de resolver as confusões espectrais predominantes. Na Erro! A origem da referência não foi encontrada. é apresenta as três principais confusões espectrais analisadas nesse trabalho e os atributos selecionados pelo especialista para eliminar essa confusão no processo de classificação.

**Tabela 1 - Confusões espectrais e atributos relacionados pelo especialista**

<b>Confusão espectral</b>	<b>Atributos selecionados</b>
Floresta X Floresta Urbana	Contexto urbano Contexto de vegetação Declividade NDVI
Campo X Floresta	Contexto Urbano NDVI
Sombra X Floresta	Contexto de vegetação NDVI

A primeira confusão espectral apresentada foi entre as classes floresta e floresta urbana. Nesse caso não existe realmente nenhuma diferença espectral entre as classes e a utilização de outros atributos que consigam identificar essas classes se torna obrigatória. A segunda confusão espectral analisada foi entre as classes campo e floresta. Essas classes em alguns pontos da imagem analisada apresentaram uma confusão espectral. Muitas vezes em áreas de borda de florestas avançando sobre campos. Em uma terceira confusão espectral foi analisado a confusão entre sombra e floresta. Essa confusão ocorre porque a classe sombra inclui somente as sombras de relevo e como se trata de imagem de alta resolução existem objetos que representam sombra de vegetação. A sombra de vegetação então e erroneamente classificada como sombra e deve ser atribuída a classe floresta na sua maioria.

#### 4.5. Fase 2: Classificação baseada em regras

A classificação baseada em regras utilizada nesse trabalho baseia-se na arquitetura dos sistemas neuro-fuzzy do tipo ANFIS conforme descrito na seção 2. Foi então construído um sistema ANFIS por confusão espectral apresentada na Erro! A origem da referência não foi encontrada.. Além dos dados identificados como discriminantes pelo especialista as pertinências as classes em questão também foram incluídas como entradas dos sistemas de inferência.

Os sistemas então foram ajustados utilizando uma imagem de um período anterior. E então os resultados analisados na imagem de teste.

## 5. Resultados experimentais

Os procedimentos apresentados nessa sessão foram realizados no software MATLAB na versão 2006a.

Para a primeira fase os padrões de treinamento foram selecionados aleatoriamente. No caso da segunda fase uma imagem e classificação do ano anterior foram utilizadas como conjunto de treinamento e ajuste das regras fuzzy. Para evitar efeitos da escolha aleatória dos dados de treinamento foram realizados 20 experimentos em cada caso e o valor apresentado e analisado é a taxa global de acerto media dos experimentos.

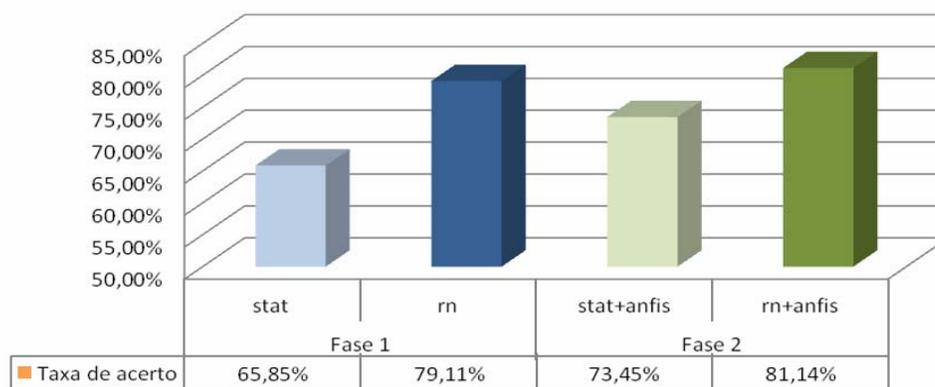


Gráfico 1 - Resultados experimentais da primeira e segunda fase

Analisando a primeira fase dos experimentos observam-se um grande incremento de desempenho com a utilização de modelos não lineares como redes neurais artificiais. Esse incremento de desempenho já era esperado assim como inúmeros outros trabalho comparando classificadores estatísticos com redes neurais artificiais. Basicamente o que retira-se desse resultado é que a premissa básica dos classificadores estatísticos, a normalidade dos dados, não é absolutamente verdadeira, especialmente em se tratando de classificação de imagens. Por outro lado a classificação não linear e o procedimento de aprendizagem adaptativa providos pelas redes neurais e pelo algoritmo de backpropagation possibilitam um resultado bem melhor.

Na segunda fase houve a inclusão das regras do especialista, essas regras foram modeladas através de sistemas fuzzy e tiveram os seus parâmetros ajustados pelo sistema ANFIS. Com a inclusão do conhecimento do especialista, ambos os procedimentos adotados na primeira fase tiveram melhoras significativas conforme os resultados anteriores. A inclusão do sistema neuro-fuzzy em conjunto com o classificador espectral estatístico (“stats+anfis”) foi capaz de aumentar a taxa de classificação correta efetivamente em cerca de sete pontos percentuais. No caso da inclusão dos sistemas neuro-fuzzy em conjunto com um classificador baseado em redes neurais artificiais houve também um incremento de desempenho, porém bem menos significativo. Uma possível explicação para esse comportamento é que a variabilidade explícita nos sistemas de regras em parte pode ser obtida através de uma análise não linear dos dados espectrais, com isso a utilização do sistema de regras poderia parcialmente suprir a deficiência dos classificadores estatísticos. Um outro ponto é que apesar de pequeno houve um incremento de desempenho na utilização das regras de classificação em conjunto com redes neurais.

Por outro lado o sistema baseado em regras oferece um meio de introdução de variáveis no procedimento de segmentação sem perder o desempenho em virtude do aumento de

complexidade no processo. Ao menos 4 novos atributos foram inseridos pelo sistema de regras, caso esses mesmos atributos fossem utilizados em conjunto com as redes neurais ou até mesmo os classificadores estatísticos supervisionados, o procedimento iria ser mais complexo necessitando de um maior número de padrões de treinamento para a convergência. Nesse sentido o procedimento de adotar regras de classificação pode ser visto vantajoso em dois pontos: primeiro prove a inclusão de regras de classificação sem o aumento da complexidade ou do conjunto de treinamento, e em segundo prove uma maneira eficiente introduzir o conhecimento do especialista no processo de classificação.

## **6. Conclusão**

Nesse trabalho a inclusão do conhecimento do especialista na tarefa de classificação automática de imagens de sensores remotos foi avaliada. Para a modelagem do conhecimento específico do foto-interprete foram utilizados sistemas neuro-fuzzy e para ajuste automático dos parâmetros dessas regras a arquitetura ANFIS e o treinamento por backpropagation foram aplicados.

Os experimentos foram realizados utilizando duas imagens IKONOS multi-espectrais da mesma região correspondente a um remanescente da Mata Atlântica no estado do Rio de Janeiro.

Para a classificação baseada em regras primeiramente foi elaborada a base de regras através de entrevistas sucessivas com especialistas, na qual também foi elaborada uma classificação de referência. Essa base então foi ajustada levando em conta os resultados obtidos pelos classificadores supervisionados somente.

Os primeiros resultados dos experimentos mostram que a inclusão da base de regras elaborada pelo foto-interprete e esta sendo ajustada por um procedimento de treinamento automático são capazes de prover ganhos sensíveis nas taxas globais de acerto tanto de métodos estatísticos de classificação quanto métodos baseados em redes neurais artificiais. Além do ganho direto na taxa de acerto global a inclusão de regras de maneira controlada e sistemática prove um método viável de introdução de atributos em um procedimento de classificação sem o aumento explosivo da complexidade dos classificadores supervisionados.

Apesar de ter mostrado que a inclusão de regras fuzzy no processo de classificação automática reflete na inclusão de conhecimento no processo e por sua vez ocasiona uma melhora sensível no procedimento, o corrente trabalho pode ser estendido da seguintes maneiras: primeiramente criando uma base de regras mais rica, nesse trabalho foram usadas apenas 3 regras desenvolvidas pelo especialista, acredita-se que com mais regras e outros dados sendo utilizados o desempenho aumente significativamente; em segundo, utilizando outros sistemas neuro-fuzzy voltados para classificação, o ANFIS utilizado não é um sistema específico para classificação e sim para controle que foi adaptado nesse trabalho para essa tarefa, porém a análise do desempenho dessa metodologia com outros sistemas de inferência baseados em regras fuzzy é importante. A extração de regras também pode ser automatizada, utilizando um procedimento automático ou semi-automático de extração por dados de treinamento.

## **Agradecimento**

À FAPERJ pelo apoio recebido para a realização desta pesquisa.

## **Referências**

Takagi, T.; Sugeno, M. "Fuzzy identification of systems and its application to modeling and control," IEEE Trans. Syst., Man, Cybern., vol. SMC-15, pp. 116–132, 1985.

- Antunes, A. F. Classificação de ambiente ciliar baseada em orientação a objetos em imagens de alta resolução. Curitiba, 2003. Tese ( Pós Graduação em Ciências Geodésicas 0) - Universidade Federal do Paraná.
- Bückner, J.; Stahlhut, O.; Pahl, M.; Leidtke C.-E. Knowledge Based Automatic Image Data Analyzer for Remote Sensing Data. In: ICSC CONGRESS ON COMPUTATIONAL INTELLIGENCE METHODS AND APPLICATIONS 2001 - CIMA 2001, 2001, Bangor, Wales, Reino Unido. Proceedings (CD ROM) of The Congress on Computational Intelligence Methods and Applications 2001 – CIMA 2001. International Computing Sciences Conventions – University of Wales in Bangor, U.K, 2001
- Leidtke C.-E.; Bückner, J.; Grau, O.; Growe, S.; Tonjes, R. AIDA: A System for the Knowledge Based Interpretation of Remote Sensing Data, In: THIRD INTERNATIONAL AIRBORNE REMOTE SENSING CONFERENCE AN EXHIBITION, 1999, Copenhagen, Dinamarca, Proceedings of the Third International Airborne Remote Sensing Conference and Exhibition, Environmental Research Institute of Michigan, AGU, 1997.
- Niemann, H.; Sagerer, G.; Schroder, S.; Kummert, F. ERNEST:A Semantic Network System for Pattern Understanding. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 12, n. 9, set 1990.
- Clement, V.; Giraudon, G.; Houzelle, S.; Sandakly F. Interpretation of Remotely Sensed Images in a Context of Mutisensor Fusion Using a Multispecialist Architecture. IEEE Transactions on Geoscience and Remote Sensing, v. 31, n. 4, p. 779-791, jul 1993.
- Matsuyama, T.; Hwang, V. Advances in computer vision and machine intelligence. SIGMA, a knowledge-based aerial image understanding system. New York: Plenum, 1990. ISBN: 030643301X
- Mckeown, D.M.; Harvey, W.A.; Mcdermott, J. Rule Based interpretation of aerial imagery. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 7, v. 5, p. 570-585, 1985.
- Thomas W.W.; Carvalho, A.M.V.; Amorim, A.M.A.; Garison, J.; Arbeláz, A.L. Plant endemism in two forests in southern Bahia, Brazil. Biodiversity and Conservation 7, p. 311-322, CIFOR/UNESCO, 1998.
- Sips, P. The Atlantic Forest of South Bahia, Brazil: Hotspot within a Hotspot. European Tropical Research Network. n. 29, p. 41- 43, 1999. Disponível em: <[http://www.etfrn.org/etfrn/newsletter/nl29\\_oip.html#theatl](http://www.etfrn.org/etfrn/newsletter/nl29_oip.html#theatl) >
- Blaschke, T.; Strobl, J. . What is wrong with pixel? Some recent developments Interfacing remote sensing and GIS. GeoBIT/GIS 6, p. 12-17, 2001.
- Rego L.F.G.; Koch, B. Automatic classification of land cover with high resolution data of the Rio de Janeiro City Brazil, In: 2<sup>nd</sup> GRSS/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas, Berlin, Germany, 22-23 Mai. 2003. Proceedings of 2<sup>nd</sup> GRSS/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas, p. 172 – 176, Mai. 2003.
- Kressler, F.P.; Kim Y.S.; Steinnocher, K.T. Object-oriented land cover classification of panchromatic KOMPSAT-1 and SPOT-5 data. In: IGARSS 2003 - International Geoscience And Remote Sensing Symposium, Jul. 21-25 2003. Proceedings of IGARSS 2003, v. 6, p.3471 – 3473, 2003.
- Elkan, C.; Berenji, H.R.; Chandrasekaran, B.; Silva, C.J.S; Attikiouzel, Y.; Doubois, D.; Prade, H.; Smets, P.; Freksa, C.; Garcia, O.N.; Klir, G.J.; Bo Yuan; Mamdani, E.H.; Pelletier, F.J.; Ruspini, E.H.; Turksen, B.; Vadiee, H.; Jamshidi, M.; Pei-Zhuang Wang; Sei-Keng Tan; Shaohua Tan; Yager, R.R.; Zadeh, L.A The paradoxical success of fuzzy logic. IEEE Expert, v.9, n. 4, p.3-49, ago. 1994.
- Jang, J.-S.R. ANFIS: Adaptive-Network-based Fuzzy Inference Systems. IEEE Transactions on Systems, Man, and Cybernetics, v. 23, n. 3, p. 665-685, mai. 1993.
- DEFINIENS e-Cognition Professional, version 4.0: multiscale image interpretation software. DEFINIENS IMAGING, 2004. Manual disponível em: <<http://www.definiens-imaging.com/>>.
- Thomas, C.E.; Gilles, D.F., Feitosa, R.Q. A New Covariance Estimate for Bayesian Classifiers in Biometric Recognition. IEEE Transaction on Circuits and System for Vídeo Technology, v. 14, p.214-223, fev. 2004.
- Haykin, S. Redes Neurais: Princípios e práticas. 2. ed. Porto Alegre: Bookman, 2001. ISBN: 85-7307-718-2.