

INTERIMAGE: UMA PLATAFORMA COGNITIVA *OPEN SOURCE* PARA A INTERPRETAÇÃO AUTOMÁTICA DE IMAGENS DIGITAIS

Interimage: an open source cognitive platform for automatic interpretation of digital images

Gilson Alexandre Ostwald Pedro da Costa¹
Carolina Moutinho Duque de Pinho²
Raul Queiroz Feitosa¹
Cláudia Maria de Almeida²
Hermann Johann Heinrich Kux²
Leila Maria Garcia Fonseca²
Dario Augusto Borges Oliveira¹

¹**Pontifícia Universidade Católica do Rio de Janeiro – PUC-RJ**
Departamento de Engenharia Elétrica
R. Marquês de São Vicente, 225 – 22453-900 Rio de Janeiro, RJ
{gilson, raul, dario}@ele.puc-rio.br

²**Instituto Nacional de Pesquisas Espaciais - INPE**
Divisão de Processamento de Imagens – Divisão de Sensoriamento Remoto
Av. dos Astronautas, 1758 – 12227-010 São José dos Campos, SP
{carolina, leila}@dpi.inpe.br; {almeida, hermann}@dsr.inpe.br

RESUMO

Este artigo introduz uma nova plataforma cognitiva *open source* destinada à interpretação automática de imagens digitais, denominada InterIMAGE. Serão apresentados neste trabalho os aspectos principais, a arquitetura, bem como uma visão geral da estratégia de interpretação implementada no InterIMAGE. Será também apresentado um experimento, no qual uma aplicação construída e testada em uma plataforma comercial (eCognition) é transposta para o InterIMAGE. Nenhuma mudança foi introduzida no modelo original de representação do conhecimento propriamente dito, apenas a maneira de formulação do conhecimento foi adaptada, de modo a ajustar-se às estruturas de representação do conhecimento no InterIMAGE. Os resultados apresentaram classificações praticamente idênticas produzidas através de ambas as plataformas.

Palavras chaves: Interpretação de imagens, classificação automática, métodos cognitivos, código aberto.

ABSTRACT

This paper introduces a new open source knowledge-based platform for automatic image interpretation, called InterIMAGE. The architecture, main features as well as an overview of the interpretation strategy implemented in InterIMAGE are presented. The paper also reports an experiment in which an application built and tested upon a commercial software (eCognition) is translated into InterIMAGE. No change was introduced in the original knowledge model itself. Only the knowledge formulation has been changed in order to comply with InterIMAGE's knowledge representation structures. The results showed practically identical classifications obtained with both platforms.

Keywords: Image interpretation, automatic classification, knowledge-based methods, open source.

1. INTRODUÇÃO

O sensoriamento remoto constitui atualmente a mais importante fonte de dados para a identificação e monitoramento de mudanças do uso e cobertura do solo na superfície terrestre, subsidiando efetivamente investigações acerca das interações entre o meio ambiente e as atividades agropecuárias, de exploração de recursos naturais e urbanas (EHLERS *et al.*, 2002).

No entanto, a presente carência de ferramentas eficientes de interpretação automática de imagens torna difícil a consecução de metas de muitas aplicações em monitoramento de mudanças de cobertura e uso do solo. O enorme tempo despendido desde a aquisição de uma imagem até a conclusão da sua classificação resulta na insuficiência de tempo hábil para fundamentar decisões críticas, que poderão evitar ou diminuir os efeitos da degradação ambiental ou expansão urbana desordenada (REGO, 2003).

Atualmente, a grande maioria das técnicas de análise de dados de sensoriamento remoto pressupõe a intensiva intervenção humana. Os programas disponíveis comercialmente para a interpretação de imagens fornecem usualmente resultados incompletos e fragmentados, os quais requerem uma revisão detalhada de um intérprete humano para a identificação e retificação das inconsistências produzidas pelos algoritmos convencionais de classificação de imagens (BÜCKNER *et al.*, 2001). Em vista disso, há uma reconhecida demanda para o desenvolvimento de técnicas robustas de interpretação e extração automáticas de informações de dados de sensoriamento remoto (BLASCHKE *et al.*, 2000; CARRION *et al.*, 2002).

Em (JAIN *et al.*, 2000) as técnicas de reconhecimento de padrões são agrupadas em categorias. Três merecem especial destaque nas aplicações que envolvem classificação de imagens de sensores remotos: a) métodos estatísticos b) métodos baseados em aprendizado de máquina e c) métodos estruturais.

Métodos estatísticos (WEB, 2002) constituem a solução denotada como convencional em sensoriamento remoto. Nesta categoria as classes de objetos são representadas por funções de densidade de probabilidade definidas em um espaço de atributos pré-selecionado. Estas funções determinam uma subdivisão do espaço em regiões em que se concentram os padrões pertencentes a cada classe. Modelar adequadamente as densidades de probabilidade é o principal desafio neste tipo de abordagem. Limitações quanto a número de padrões de treinamento disponíveis freqüentemente impõem a adoção de modelos simples o que pode redundar num desempenho insatisfatório do classificador.

Técnicas baseadas em aprendizado de máquina (LI *et al.*, 2000; MCIVER *et al.*, 2001; ZHONG *et al.*, 2008; CHI e ERSOY, 2005), ao contrário, visam aprender relações complexas entre entrada e saída a partir de exemplos, mesmo na ausência de modelos

explícitos. Sua principal desvantagem está na elevada demanda por padrões de treinamento, o que as exclui como alternativa para muitas aplicações práticas de sensoriamento remoto.

Métodos estruturais envolvem padrões complexos. Adota-se uma abordagem hierárquica que prevê descrições de como padrões ou classes de padrões são formados a partir de padrões cada vez mais simples até as chamadas primitivas. Importantes neste contexto são os chamados sistemas baseados em conhecimento ou cognitivos (LIEDTKE *et al.*, 1997; BÜCKNER *et al.*, 2001; SCHIEWE *et al.*, 2001; CENTENO *et al.*, 2003). Ao contrário do aprendizado de máquina, o foco nestes sistemas está na representação explícita de conhecimento *a priori* a respeito das relações entre padrões. Este conhecimento, tipicamente coletado de um especialista humano, reduz a demanda por padrões de treinamento para modelagem do problema.

As plataformas convencionais de análise de imagens, que operam apenas com métodos estatísticos, mostram-se limitadas quando se pretende uma detecção de alvos com maior nível de complexidade. Nesse sentido, alguns programas comerciais para a interpretação de imagens têm sido lançados, visando superar as limitações impostas por classificadores convencionais. Como exemplos, podem ser citados os pacotes de software Feature Analyst, que utiliza uma abordagem baseada em aprendizado de máquina, além do ERDAS, do módulo Feature Extraction do ENVI e do sistema Definiens, que utilizam uma abordagem estruturada, baseada em conhecimento.

O Feature Analyst, produzido pela empresa Visual Learning Systems, funciona como um módulo dos programas ERDAS, ArcGIS, GeoMedia e SOCET SET. Esse software é um extrator de feições que, a partir de amostras de treinamento selecionadas pelo usuário, monta uma base de conhecimento utilizando ferramentas de inteligência computacional, como redes neurais.

No ERDAS há um conjunto de funcionalidades chamado Knowledge Engineer no qual é possível definir regras de decisão, estruturadas em uma rede hierárquica, que são usadas em um processo de classificação baseado em pixels.

O módulo Feature Extraction do ENVI implementa um processo de classificação baseado em objetos, que utiliza uma rede semântica, na qual são definidos limiares para atributos espaciais, espectrais e texturais das regiões (objetos) na imagem.

A interpretação de imagens através do sistema Definiens (anteriormente denominado eCognition) também segue uma abordagem cognitiva, baseada em objetos. Como no Feature Extraction, classes de objetos são organizadas numa rede semântica. Adicionalmente, há a possibilidade de customização de atributos, uso de regras nebulosas e múltiplos níveis de segmentação.

Embora essa nova geração de programas represente um substancial avanço em relação aos classificadores convencionais, persistem ainda desafios a serem vencidos no campo de interpretação automática

de imagens, de forma a assegurar uma maior exatidão e riqueza na extração de detalhes sobre os alvos e na classificação.

Neste artigo, são apresentados os aspectos principais e a arquitetura de um sistema de interpretação de imagens baseado em conhecimento, ou cognitivo. Esse sistema, denominado InterIMAGE, é uma plataforma em código aberto (*open source*), desenvolvida conjuntamente pelo Laboratório de Visão Computacional do Departamento de Engenharia Elétrica da Pontifícia Universidade Católica do Rio de Janeiro (LVC/PUC-RJ) e pela Divisão de Processamento de Imagens do Instituto Nacional de Pesquisas Espaciais (DPI-INPE).

São também apresentados os resultados de um experimento de interpretação de uma imagem Quickbird, referente à classificação de cobertura do solo urbano da porção sul da cidade de São José dos Campos, SP. Esse experimento de classificação foi baseado em um trabalho de PINHO (2005), implementado originalmente no programa eCognition, versão 4.0 (SCHIEWE *et al.*, 2001). O modelo de conhecimento concebido nesse trabalho foi adaptado às estruturas de representação do conhecimento no InterIMAGE, e a interpretação foi conduzida com base no mesmo conjunto de dados de entrada. Na seqüência, foi feita uma comparação dos resultados de interpretação produzidos por ambas as plataformas.

As características básicas do InterIMAGE são descritas na Seção 2, e a estratégia de interpretação implementada pelo sistema é apresentada na Seção 3. Na Seção 4, é descrito o experimento de classificação de cobertura do solo urbano, cujos resultados são apresentados e discutidos na Seção 5. Finalmente, as conclusões e direções para trabalhos futuros são expostas e comentadas na Seção 6.

2. DESCRIÇÃO DO SISTEMA

O InterIMAGE se baseia no sistema GeoAIDA (BÜCKNER *et al.*, 2001), desenvolvido pelo TNT – Instituto para Tecnologia da Informação da Universidade de Hannover, Alemanha –, tendo herdado daquele sistema seu desenho funcional básico, estruturas de conhecimento e mecanismos de controle.

De fato, a implementação do InterIMAGE teve como ponto de partida o código criado no TNT. Funcionalmente os dois sistemas são, por ora, bastante semelhantes, de tal forma que as características apresentadas nesta seção e a estratégia de interpretação, apresentada na Seção 3, podem ser usadas para descrever ambos os sistemas. O InterIMAGE conta, porém, com diversas inovações em relação ao seu antecessor, como novas funções para as regras de decisão – incluindo as que tornaram possível a implementação do modelo de conhecimento apresentado neste trabalho (Seção 4).

No momento, encontram-se em desenvolvimento uma nova interface gráfica de usuário, ferramentas de depuração de modelos de interpretação,

mecanismos de controle para classificação multitemporal, bem como novos operadores de processamento de imagens. Além disso, enquanto o GeoAIDA funciona unicamente no sistema operacional Linux, o InterIMAGE é um sistema multi-plataforma, possuindo atualmente versões para Linux e Windows XP.

De forma sumária, o InterIMAGE implementa uma estratégia específica de interpretação de imagens, baseada e guiada por uma descrição hierárquica do processo de interpretação, estruturado em uma rede semântica.

O processo de interpretação de imagens digitais usa resultados de operadores de processamento de imagens. Nesse contexto, um operador de processamento de imagens é qualquer operador que produza como resultado uma imagem rotulada a partir de uma imagem original. Tais operadores de processamento de imagens são denominados “operadores de classificação”. Eles podem realizar operações de limiarização, basearem-se em medidas de textura ou em outros atributos quaisquer, e, assim, compor o procedimento de interpretação de uma cena.

Na maior parte dos sistemas que utilizam redes semânticas para a representação do conhecimento, somente os “nós-folha” da rede podem ser associados a operadores de processamento de imagens. Essa abordagem pode resultar numa excessiva carga computacional, uma vez que todos os objetos da imagem devem ser necessariamente avaliados por todos os operadores.

No InterIMAGE, operadores chamados holísticos (LIEDTKE *et al.*, 1997) podem ser usados para reduzir este problema. Trata-se de operadores de classificação que se destinam a identificar objetos correspondentes aos conceitos representados pelos nós da rede semântica.

O termo “holístico” se refere ao fato de que tais operadores permitem identificar objetos sem que seja necessário identificar seus componentes estruturais (de nível semântico mais baixo), associados aos nós descendentes da rede semântica.

Os operadores holísticos podem, portanto, ser conectados a qualquer nó da rede semântica, e sua tarefa básica consiste em realizar uma classificação preliminar da imagem em grupos de regiões, e assim definir quais das etapas subseqüentes do processo de interpretação serão aplicadas a cada grupo. Desta forma, nem todas as etapas seguintes serão aplicadas a todos os objetos da imagem, o que contribui para uma melhor eficiência computacional. A interpretação estrutural das regiões que se segue pode confirmar ou eventualmente refutar os resultados produzidos pelos operadores holísticos.

À medida que a interpretação dos dados progride, podem surgir avaliações conflitantes para um mesmo objeto. Tais conflitos podem ser resolvidos recorrendo a alguma forma de conhecimento prévio codificado em regras de decisão também associadas aos nós da rede semântica. Ademais, como diferentes operadores podem processar diferentes tipos de dados, o

sistema permite a análise integrada de imagens e de dados de SIG de múltiplas origens.

O InterIMAGE é particularmente flexível no que diz respeito à integração de operadores desenvolvidos por terceiros, cabendo mencionar, contudo, que a versão atual utiliza preferencialmente um repositório de operadores baseados em funcionalidades providas pela biblioteca TerraLib (CÂMARA, 2000).

3. ESTRATÉGIA DE INTERPRETAÇÃO

No InterIMAGE, o conhecimento explícito sobre os objetos, extraível a partir da própria cena, é modelado em uma rede semântica, definida pelo usuário através de uma interface gráfica.

Uma rede semântica, tal como a apresentada na Figura 1, contém nós e arcos, na qual os nós representam conceitos, e os arcos, os relacionamentos entre os conceitos. Em cada nó conceitual, define-se a informação necessária para a análise, como, por exemplo, o operador holístico especializado na busca de ocorrências do referido conceito. Durante a análise, guiada pela rede semântica, o sistema comanda a execução dos operadores e gera uma rede de instâncias, cada instância definindo uma região geográfica associada a um conceito específico.

A interpretação de dados de sensoriamento remoto consiste em produzir uma descrição estrutural e pictórica dos dados de entrada que represente o resultado pretendido da análise. No InterIMAGE, o processo de interpretação produz ao final uma descrição estrutural do resultado (uma rede de instâncias) e mapas temáticos. Os resultados intermediários e final, em termos de descrição de regiões, são armazenados em formato XML, e podem ser usados para avaliações externas a posteriori.

O processo de análise executado pelo InterIMAGE consiste de duas etapas: uma chamada “top-down” e outra “bottom-up”. A etapa *top-down* é guiada por modelo (*model-driven*) e produz uma rede de hipóteses sobre objetos na imagem, em conformidade com o modelo representado na rede semântica. A análise integrada das hipóteses para a sua confirmação ou refutação é tarefa da etapa *bottom-up*, que, por sua vez, é guiada por dados (*data-driven*). Portanto, a rede final de instâncias resulta da análise realizada na etapa *bottom-up*.

Conforme exposto anteriormente, o usuário define nos nós da rede a informação necessária para a execução de cada passo do processamento, ou seja, o operador de processamento de imagens e os valores de seus respectivos parâmetros para serem usados na etapa *top-down*, além das regras de decisão para serem aplicadas na etapa *bottom-up*.

Na etapa *top-down*, os operadores criam hipóteses – associadas a regiões geográficas – sobre a ocorrência dos conceitos representados na rede semântica. Essa tarefa é realizada de forma recursiva, partindo dos nós superiores em direção aos inferiores.

Quando a análise *top-down* alcança os nós-folha, a análise converte-se de *model-driven* para *data-driven* (*bottom-up*). As regras de decisão para a etapa *bottom-up* são definidas através de uma linguagem específica de pilhas, que contém funções para a resolução de eventuais conflitos espaciais entre as hipóteses geradas na etapa *top-down*.

4. MODELO DE CONHECIMENTO DO EXPERIMENTO

O experimento conduzido neste trabalho objetivou avaliar o desempenho do InterIMAGE em uma aplicação de interpretação específica, executada previamente no programa eCognition, distribuído comercialmente pela empresa Definiens AG. De igual forma, esse experimento objetivou avaliar a possibilidade de transposição de um modelo de conhecimento implementado no eCognition para o InterIMAGE.

De acordo com o anteriormente exposto, o experimento se refere à classificação de cobertura do solo urbano da porção sul da cidade de São José dos Campos, SP (PINHO, 2005). O conjunto de dados de entrada utilizado no eCognition (imagem Quickbird e dados vetoriais georreferenciados correspondentes ao limites das ruas) foi mantido. No entanto, para este experimento no InterIMAGE, apenas uma subcena da imagem Quickbird originalmente utilizada, contendo uma área correspondente a 129.600 m², foi utilizada.

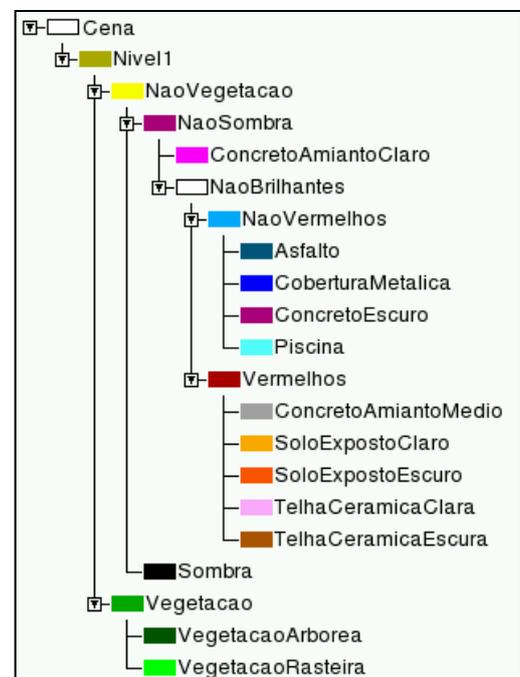


Fig. 1 – Rede Semântica.

Como o foco do experimento era justamente avaliar a dificuldade de se traduzir um modelo de conhecimento construído no eCognition para o InterIMAGE, o experimento foi projetado de modo a eliminar todas as causas potenciais de discrepâncias

entre os resultados produzidos pelas duas plataformas, com exceção, é claro, da maneira particular com que o conhecimento é representado em cada sistema. Assim sendo, utilizaram-se no InterIMAGE as mesmas regiões geradas pelo algoritmo de segmentação do eCognition, e também os mesmos valores de atributos para os respectivos segmentos. Um operador *top-down* foi especialmente desenvolvido para essa finalidade, o qual foi responsável por importar a segmentação e correspondentes valores de atributos exportados pelo eCognition.

Também foi desenvolvida para este experimento uma função destinada a calcular valores de pertinência nebulosa para serem usados nas regras de decisão da etapa de interpretação *bottom-up*. A Figura 1 apresenta a rede semântica definida no InterIMAGE. Deve-se observar que essa rede é muito semelhante à hierarquia de classes definida no eCognition, sendo que as pequenas diferenças podem ser atribuídas a detalhes das estratégias de interpretação desses dois sistemas.

5. RESULTADOS E DISCUSSÃO

A Figura 2 mostra os resultados da interpretação, condensados em um mapa temático que apresenta a classificação final produzida pelo InterIMAGE.

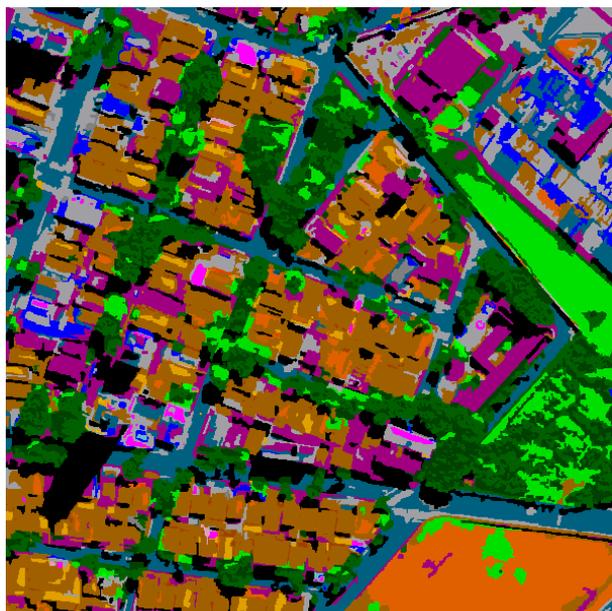


Fig. 2 – Resultados da classificação.

A Tabela 1 apresenta a matriz de confusão entre as duas classificações. As linhas da matriz mostram os resultados da classificação obtidos com o InterIMAGE, e as colunas indicam os resultados obtidos com o eCognition.

O resultado final em termos de exatidão global entre as duas classificações é de 96,2%. Essa pequena discrepância nos resultados de uma classificação para outra pode ser atribuída a um problema de precisão ao reproduzir no InterIMAGE as funções de pertinência

definidas no modelo de conhecimento do eCognition. A dificuldade está em que não se pode copiar exatamente as curvas que representam estas funções no eCognition, pois as posições exatas dos vértices destas curvas não são informadas. Portanto, as funções que foram implementadas no InterIMAGE são apenas aproximações daquelas definidas no eCognition. Essa explicação para a discrepância observada é endossada pelo fato de que a confusão ocorreu principalmente entre as classes com características semelhantes, como é o caso de *Asfalto com Concreto Escuro*, e de *Cobertura Cerâmica com Solo Exposto*.

6. CONSIDERAÇÕES FINAIS

Este trabalho apresentou o InterIMAGE, uma nova plataforma cognitiva para a interpretação automática de imagens digitais, desenvolvida em consonância com a filosofia código aberto. De igual forma, este artigo reportou um experimento, no qual um modelo de interpretação construído no eCognition foi transposto para o InterIMAGE. Os resultados da classificação obtidos por ambas as plataformas revelaram-se muito semelhantes.

Em termos de estratégia de interpretação, a implementada pelo InterIMAGE – uma combinação da abordagem guiada por modelo (*model-driven*) com a abordagem guiada pelos dados (*data-driven*) – é comparativamente mais flexível do que a do eCognition, que segue uma estratégia unicamente guiada pelos dados (*data-driven*). Assim sendo, o InterIMAGE oferece elementos adicionais para a modelagem do conhecimento não disponíveis no eCognition.

Além disso, o InterIMAGE possui uma arquitetura computacional modular, no sentido em que novos operadores holísticos – especializados na identificação de classes de objetos específicas – podem ser facilmente acoplados ao sistema, permitindo que ele seja estendido funcionalmente pelos próprios usuários, o que é consistente com um projeto de código aberto. De fato, qualquer componente do InterIMAGE, inclusive seu núcleo, pode ser aprimorado por iniciativa direta da comunidade de usuários, o que oferece possibilidades de trabalho e colaboração científica num nível muito maior do que o possível com uma ferramenta comercial, de código fechado, como o eCognition.

Os resultados do experimento descrito neste artigo são coerentes com a expectativa dos autores de que, de um modo geral, modelos de interpretação construídos no eCognition podem ser transpostos para o InterIMAGE com pouco esforço de reprogramação. No caso da aplicação particular apresentada neste artigo, a maior parte do esforço foi despendido reescrevendo as regras de decisão dentro da plataforma InterIMAGE.

Com o desenvolvimento futuro já contratado do ambiente InterIMAGE, a tarefa de tradução de modelos do eCognition para o InterIMAGE tornar-se-á progressivamente mais fácil.

O desenvolvimento subsequente do InterIMAGE já está em andamento e inclui a implementação de rotinas multitemporais, ferramentas de depuração de modelos de interpretação, assim como novos operadores de processamento de imagens.

TABELA 1 – MATRIZ DE CONFUSÃO.

InterIMAGE \ eCognition	Asfalto	Cobertura Metálica	Concreto/ Cimento Amianto Claro	Concreto/ Cimento Amianto Médio	Concreto Escuro	Piscina	Solo Exposto	Sombra	Cobertura Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Total
Asfalto	380				1							381
Cobertura Metálica		109										109
Concreto / Cimento Amianto Claro			65									65
Concreto / Cimento Amianto Médio				632			11		4			647
Concreto Escuro	49				446							495
Piscina						2						2
Solo Exposto							99		21			120
Sombra								450				450
Cobertura Cerâmica				4			93		1090			1187
Vegetação Arbórea										1130		1130
Vegetação Rasteira										4	323	327
Total	429	109	65	636	447	2	203	450	1115	1134	323	4913

AGRADECIMENTOS

Os autores agradecem à FAPERJ (*Fundação de Amparo à Pesquisa do Estado do Rio de Janeiro*) e à FINEP (*Financiadora de Estudos e Projetos*) pelo apoio.

REFERÊNCIAS BIBLIOGRÁFICAS

BLASCHKE, T.; LANG, S.; LORUP, E.; STROBL, J.; ZEI, P. Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications. In: CREMERS, A., GREVE, K. ed. **Environmental Information for Planning, Politics and the Public**. Marburg: Metropolis-Verlag, 2000. 2 v. p. 555-570.

BÜCKNER, J.; PAHL, M.; STAHLHUT, O.; LIEDTKE, C.-E. GEOAIDA - A knowledge-based automatic image data analyzer for remote sensing data.

In: ICSC CONGRESS ON COMPUTATIONAL INTELLIGENCE METHODS AND APPLICATIONS 2001 - CIMA 2001, Bangor, Wales, UK. **Proceedings of the Congress on Computational Intelligence Methods and Applications 2001 - CIMA 2001 (CD-ROM)**.

CÂMARA, G.; SOUZA, R. C. M.; PEDROSA, B. M.; VINHAS, L.; MONTEIRO, A. M. V.; PAIVA, J. A.; CARVALHO, M. T.; GATASS, M. TerraLib: Technology in Support of GIS Innovation. In: II Brazilian Symposium on GeoInformatics, GEOINFO 2000. São Paulo, Brazil. **Proceedings of GEOINFO 2000, (CD-ROM)**.

CARRION, D.; GIANINETTO, M.; SCAIONI, M. GEOREF: A software for improving the use of remote sensing images in environmental applications. In: IEMSS 2002 - INTEGRATED ASSESSMENT AND DECISION SUPPORT, 2002, Lugano, Switzerland. **Proceedings of IEMSS 2002, 2 v., p. 360**.

CENTENO, J. A. S.; ANTUNES, A. F. B.; TREVIZAN, S.; CORREA, F. Mapeamento de áreas permeáveis usando uma metodologia orientada a regiões e imagens de alta resolução. **Revista Brasileira de Cartografia**, n. 55/01, p. 48-56, Jul. 2003.

CHI, H.M.; ERSOY, O.K. A statistical self-organizing learning system for remote sensing classification, **IEEE Transactions on Geoscience and Remote Sensing**, v. 43, , Ag. 2005, p.1890 – 1900.

LI, D.; Di, K., LI, D. Land Use Classification of Remote Sensing Image with GIS on Spatial Data Mining Techniques, **International Archives of Photogrammetry and Remote Sensing**, v. XXXIII, Part B3, 2000, p. 238-245.

EHLERS, M.; JANOWSKY, R.; GÄHLER, M. New remote sensing concepts for environmental monitoring. In: Ehlers, M. ed. Conf. on Remote Sensing for Environmental Monitoring, GIS Applications, and Geology, 2002, Bellingham, WA. **Proceedings SPIE**, v. 4545, p. 1-12,

GRAHAM, J.; JONES, P.: **Knowledge-based image processing systems**. London: Springer-Verlag, 1997. 178 p.

JAIN, K.; DUIN R.; MAO, J. Statistical Pattern Recognition: A Review, **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, n. 1, p. 4-37, 2000

LIEDTKE, C.-E.; BÜCKNER, J.; GRAU, O.; GROWE, S.; TÖNJES, R. AIDA: A system for the knowledge-based interpretation of remote sensing data. In: THIRD INTERNATIONAL AIRBORNE REMOTE SENSING CONFERENCE AND EXHIBITION, 1999, Copenhagen, Denmark, **Proceedings of the Third International Airborne Remote Sensing Conference and Exhibition**. Environmental Research Institute of Michigan, AGU, 1997.

MCIVER, D. K.; FRIEDL, M.A. Estimating pixel-scale land cover classification confidence using nonparametric machine learning methods, **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n. 9, September 2001, p. 1959-1968.

PAHL, M. **Arquitetura de um sistema baseado em conhecimento para a interpretação de dados de sensoriamento remoto de múltiplos sensores**. 95 p. (INPE-15211-TAE/71). PhD Thesis - Universidade de Hannover, (Tradução) São José dos Campos. 2008. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m17@80/2008/03.07.18.31>>. Acesso em: 26 set. 2008.

PINHO, C.M.D. **Análise orientada a objetos de imagens de satélite de alta resolução espacial**

aplicada à classificação de cobertura do solo no espaço intra-urbano: o caso de São José dos Campos-SP. São José dos Campos, 181 p. Dissertação (Mestrado em Sensoriamento Remoto, INPE, 2005 (INPE-14183-TDI/1095).

REGO, L. F. G.; **Automatic land-cover classification derived from high-resolution IKONOS satellite image in the urban Atlantic forest in Rio de Janeiro (Brazil) by means of an object-oriented approach**. 2003. 193p. Tese (Forstwissenschaftlichen Fakultät). Albert-Ludwigs-Universität, 2003.

SCHIEWE, J., TUFTE, L., EHLERS, M. Potential and problems of multi-scale segmentation methods in remote sensing. **Geo-Information-Systeme**, v. 6, p. 34-39, 2001.

WEBB, A. R. **Statistical Pattern Recognition**, Second Edition, Wiley, 2002

ZHONG, P.; ZHANG, P. ; WANG, R. Dynamic Learning of SMLR for Feature Selection and Classification of Hyperspectral Data, **IEEE Geoscience and Remote Sensing Letters** ,v 5, n 2, Abril 2008, p. 280 – 284.