

Classificação da cobertura da Terra com base em dados de sensores multiespectrais/hiperespectrais embarcados em satélites: uma revisão sistemática da literatura

James Roberto Bombasar¹, Eros Comunello¹, Antonio Carlos Sobieranski¹, Anita Maria da Rocha Fernandes¹

¹Mestrado em Computação Aplicada – Universidade do Vale do Itajaí (UNIVALI)
Caixa Postal 360 – CEP 88302-202 – Itajaí – SC – Brasil

bombasar@gmail.com, {eros.com, asobieranski,
anita.fernandes}@univali.br

***Abstract.** The land cover classification using satellite images has been the subject of research in the image processing area over the past few years. The variety of remote sensors monitoring the Earth provides a field for implementation and evaluation of different computational classification techniques. Within a systematic literature review, the goal of this paper is to provide an overview on the multispectral/hyperspectral satellite data classification techniques proposals in last five years. At the end, we present the review results and the study conclusions.*

***Resumo.** A classificação da cobertura da Terra com base em imagens de satélites tem sido tema de parte da pesquisa na área do processamento de imagens ao longo dos últimos anos. A diversidade de sensores remotos que atualmente monitoram a Terra fornece um campo para que diferentes técnicas computacionais de classificação sejam aplicadas e avaliadas. Através de uma revisão sistemática da literatura, o presente trabalho tem como objetivo fornecer um panorama sobre as principais técnicas de classificação de dados de satélite multiespectrais/hiperespectrais propostas nos últimos cinco anos. Ao final, são apresentados os resultados da revisão e as conclusões do estudo.*

1. Introdução

A cobertura da Terra é uma síntese de vários fatores naturais e intervenções humanas, incluindo vegetações, solos, geleiras, construções, dentre outros tipos de cobertura [Li *et al.* 2011]. A atividade que tem como objetivo mapear esses diferentes tipos de cobertura em determinado momento e espaço é denominada Classificação da Cobertura da Terra, em inglês *Land Cover Classification* (LCC) [Marconcini, Fernandez-Prieto e Buchholz 2014]. A LCC fornece informações importantes para a restauração e a melhoria do ambiente ecológico [Li *et al.* 2011] e representa uma das mais importantes aplicações das imagens de sensoriamento remoto [Dai e Liu 2010; Jin *et al.* 2011].

Atualmente, a LCC conta com uma grande facilidade, a existência de diversas bases de dados, tais como *landsat.usgs.gov* e *modis.gsfc.nasa.gov*, que disponibilizam imagens de satélites com diferentes resoluções e formas de captura. Extrair informações precisas e úteis sobre cobertura da Terra, no entanto, não depende só das características das imagens, mas também das técnicas de classificação utilizadas. Pesquisas na área de

processamento de imagens têm utilizado diversos tipos de classificadores ao longo dos últimos anos, tais como *Minimum Mahalanobis Distance* (MMD), *Maximum Likelihood Classifier* (MLC), *K-nearest neighbor* (KNN), *Artificial Neural Network* (ANN), *Decision Tree Classifier* (DTC) e *Support Vector Machine* (SVM) [Huo *et al.* 2012].

Através de uma revisão sistemática da literatura, ou SLR (*Systematic Literature Review*), o principal objetivo deste trabalho é identificar as principais técnicas para a classificação de dados de sensores multiespectrais e/ou hiperespectrais propostas nos últimos cinco anos, bem como avaliar as características dos estudos em que cada uma delas foi aplicada, tendo em vista que a acurácia de uma classificação está diretamente relacionada com a sua configuração e as características dos dados de entrada.

Após a introdução (tópico 1), são apresentados os conceitos relacionados com o tema de pesquisa (tópicos 2 e 3). O tópico seguinte (4) apresenta os principais trabalhos relacionados, identificados através de uma pesquisa exploratória. Após a descrição detalhada da SLR (tópico 5), são relatados e analisados os resultados obtidos (tópico 6). Ao final (tópico 7) são apresentadas as conclusões do estudo.

2. Classificação da cobertura da terra

A Classificação da Cobertura da Terra, em inglês *Land Cover Classification* (LCC), tem com objetivo mapear os tipos de cobertura da Terra em determinada área geográfica e determinado momento através de imagens, ela representa uma das principais aplicações das tecnologias de observação da Terra por satélite [Marconcini, Fernandez-Prieto e Buchholz 2014].

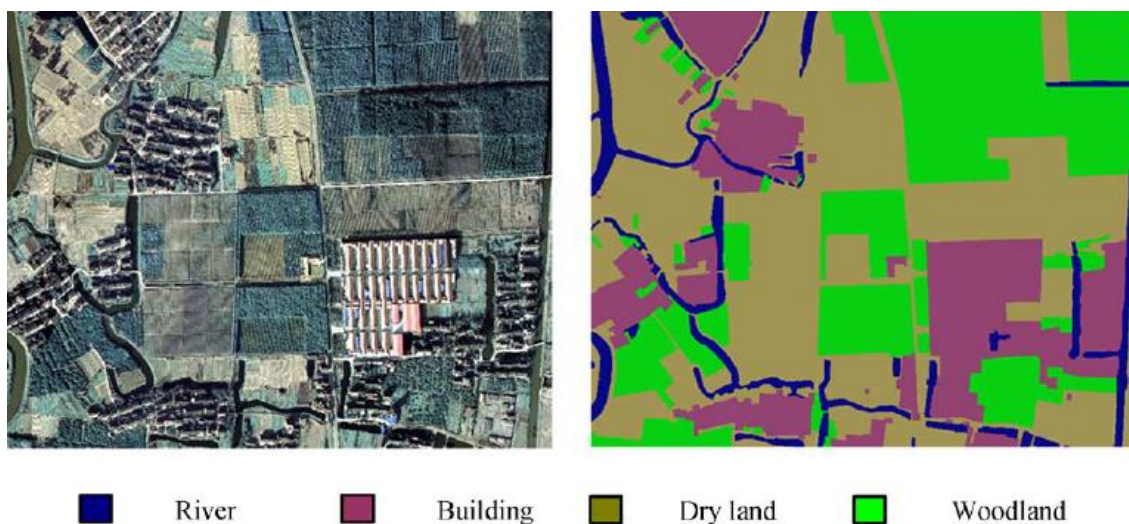


Figura 1. LCC com imagens do satélite SPOT 5 [Huo *et al.* 2012]

Basicamente, a LCC consiste na atribuição de uma classe de interesse para cada pixel da imagem. A Figura 1 mostra uma LCC realizada por Huo *et al.* (2012). No lado esquerdo, uma imagem da região de Shanghai capturada pelo satélite SPOT 5. No lado oposto, a imagem obtida após a classificação dos pixels em quatro classes distintas: Rio (*River*), Construção (*Building*), Terra seca (*Dry land*) e Floresta (*Woodland*).

O pré-processamento de imagem é uma etapa bastante comum em LCC, e pode envolver desde a aplicação de algoritmos para eliminar a contaminação de nuvens, tal como em Ye *et al.* (2010), até mesmo a fusão/combinção de imagens de diferentes momentos (séries temporais) e faixas espectrais de captura (visível, infravermelho), tal como em Li *et al.* (2011) e Dai (2010), respectivamente.

No que diz respeito às classes de interesse, algumas variações da terminologia LCC são encontradas na literatura, tais como *Land Use And Land Cover Classification* (LULC) [Song *et al.* 2009] e *Target Land Cover Classification* (TLCC) [Marconcini, Fernandez-Prieto e Buchholz 2014]. Giri (2012) explica que o termo *Land Cover* (LC) refere-se às vegetações e construções artificiais que cobrem a Terra, enquanto que o termo *Land Use* (LU) refere-se às atividades humanas sobre a Terra. A TLCC, por sua vez, tem como o objetivo a identificação de classes de interesse específico, podendo ser utilizada na área da agricultura, por exemplo, para a identificação de diferentes tipos de cultivos, tal como apresentado em Marconcini, Fernandez-Prieto e Buchholz (2014).

3. Sensoriamento remoto multiespectral e hiperespectral

O sensoriamento remoto é uma técnica que permite a obtenção de dados sobre a superfície da Terra através de sensores. O nome “remoto” se dá pelo fato do sensor não estar em contato físico com a Terra. A utilização de satélites como veículos para os sensores é mais comum que a de aviões em função da melhor relação custo-benefício, tendo em vista que um satélite pode permanecer por vários anos em órbita gerando dados 24 horas por dia.

Os sensores multiespectrais (poucas bandas) e hiperespectrais (muitas bandas contíguas) são aqueles que incluem diferentes faixas do espectro eletromagnético, normalmente nas regiões visual e infravermelha. Como exemplo, o Quadro 1 apresenta as bandas (faixas) do satélite multiespectral Landsat da NASA, que tem como principal objetivo transmitir imagens da Terra para fins de monitoramento das condições ambientais do planeta [Gonzalez e Woods 2010].

Existe outro tipo de sensor remoto que não faz parte do escopo deste trabalho, o Radar de Abertura Sintética (SAR - *Synthetic Aperture Radar*), que opera com micro-ondas e também fornece dados que podem ser utilizados na LCC, tal como em Mittal, Singh e Saini (2014) e Shiraishi *et al.* (2014). Sensores do tipo SAR conseguem capturar dados sobre a cobertura da Terra mesmo com a existência de condições atmosféricas adversas (nuvens, por exemplo).

As tecnologias de sensoriamento remoto podem monitorar a superfície da Terra com diferentes resoluções espaciais e espectrais [Liu *et al.* 2013]. A resolução espacial determina o tamanho mínimo (normalmente expresso em metros) que um alvo deve possuir para que ele possa ser identificado pelo sensor. A resolução espectral, por sua vez, determina que tipos de informações sobre a cobertura da terra o sensor é capaz de fornecer (ver campo “Características e utilizações” do Quadro 1).

Segundo Stavrakoudis *et al.* (2012), os sensores multiespectrais são adequados para classificações em nível de gênero, e os hiperespectrais para classificações em nível de gênero e espécie, como no caso das florestas, onde normalmente diferentes espécies do mesmo gênero coexistem.

Quadro 1. Bandas espectrais do Landsat [Adaptado de Gonzalez e Woods 2010]

Número	Nome	Resolução Espacial (m)	Faixa Espectral (μm)	Características e utilizações
1	Azul visível	30	0,45-0,52	Máxima penetração na água
2	Verde visível	30	0,52-0,60	Bom para mensuração do vigor de plantas
3	Vermelho visível	30	0,63-0,69	Discriminação de vegetação
4	Infravermelho próximo	30	0,76-0,90	Mapamento de biomassa e linha costeira
5	Infravermelho médio	30	1,55-1,75	Conteúdo de umidade e solo e vegetação
6	Infravermelho termal	60	10,4-12,5	Umidade do solo, mapeamento térmico
7	Infravermelho médio	30	2,08-2,35	Mapeamento mineral

4. Trabalhos relacionados

A literatura recente apresenta estudos que buscam identificar, comparar e/ou avaliar diferentes técnicas de LCC. Mahmon e Ya'acob (2014) têm como objetivo investigar a capacidade de Redes Neurais Artificiais (RNAs) para classificar as imagens de satélite usando diferentes algoritmos de treinamento. Os estudos de Mittal, Singh e Saini (2014) e Shiraishi *et al.* (2014), por sua vez, têm como objetivo analisar e avaliar técnicas de LCC com base em sensoriamento remoto por radar.

Gomez-Chova *et al.* (2015) apresentam uma revisão da literatura sobre técnicas de LCC multimodais, que consistem na combinação/fusão de diferentes imagens com o objetivo de melhorar a acurácia da classificação. Os autores entendem que a revisão e a discussão sobre este tipo de técnica são importantes porque atualmente diferentes tipos de dados (de radar, multiespectrais, hiperespectrais, multi-temporais e multiangulares) de um mesmo local estão disponíveis.

5. Metodologia

A fim de identificar as principais técnicas para a classificação de dados de sensores multiespectrais e/ou hiperespectrais propostas nos últimos cinco anos, foi utilizada a metodologia de revisão sistemática da literatura ou SLR (*Systematic Literature Review*), um tipo de estudo que visa identificar, analisar e interpretar evidências a respeito de uma pergunta de pesquisa específica e que segue um procedimento bem definido e, até certo grau, não tendencioso [Kitchenham e Charters 2007].

Kitchenham e Charters (2007) sugerem que as atividades de uma SLR sejam agrupadas três etapas: planejamento, execução e relato. A primeira etapa envolve ao menos três atividades: identificação da necessidade da SLR, formulação da pergunta de pesquisa e desenvolvimento do protocolo de revisão. Como atividades da segunda etapa, tem-se: identificação da pesquisa; seleção e avaliação dos estudos; extração e síntese de

dados. A formatação e avaliação do relatório, bem como a especificação do mecanismo de divulgação, representam as atividades da terceira e última etapa.

Os tópicos seguintes descrevem as etapas de planejamento e execução da SLR objeto deste trabalho. Em seguida (tópico 6), são apresentados os resultados (relatório).

5.1. Planejamento

Através de uma pesquisa exploratória realizada em agosto de 2015 na base IEEEExplore¹ com o termo de busca “*land cover classification*”, verificou-se a existência de um grande número de trabalhos sobre LCC. Verificou-se, também, que as técnicas descritas nos resumos dos trabalhos são bastante diversificadas, o que apontou para a necessidade de uma SLR que respondesse à seguinte pergunta de pesquisa:

Quais foram as principais técnicas para a classificação de dados de sensores multiespectrais e/ou hiperespectrais propostas nos últimos cinco anos?

No protocolo da SLR, foram incluídas as bases de dados IEEEExplore Digital Library e ScienceDirect. Para cada uma das bases, foi definida uma estratégia de busca específica (Quadro 2), considerando-se, para tal, os termos “*land cover classification*” e “*algorithm*”, bem como as ferramentas de pesquisa disponíveis em cada caso.

Quadro 2. Estratégias de busca

Base de dados	Estratégia de busca
IEEEExplore (ieeexplore.ieee.org)	<i>("Document Title": "land cover classification") AND algorithm</i>
ScienceDirect (sciencedirect.com)	<i>pub-date > 2009 and TITLE("land cover classification") and TITLE-ABSTR-KEY(algorithm)</i>

Para a seleção das publicações, foram estabelecidos os seguintes critérios: ter sido publicada entre 2010 e 2015; conter o termo “*land cover classification*” no título e o termo “*algorithm*” no título, resumo ou palavras-chave; propor alguma técnica de LCC baseada em imagens de sensores multiespectrais e/ou hiperespectrais embarcados em satélites. Os critérios de exclusão utilizados foram: não relatar algum experimento com a técnica proposta; não fornecer os seguintes dados: a) região estudada; b) sensor; c) quantidade de classes em estudo; d) algoritmos de classificação utilizados; e) acurácia global obtida com a aplicação da técnica.

Para o processo de extração dos dados, foram estabelecidos os seguintes campos: referência da publicação (ano e autores), nome do satélite/sensor que capturou as imagens utilizadas; resolução espacial, número de classes em estudo, classificadores utilizados e acurácia global da técnica proposta.

5.2. Execução

A execução das estratégias de busca apresentadas no Quadro 2 em 08/09/2015 forneceu 61 resultados: 48 e 13 nas buscas em IEEE e ScienceDirect, respectivamente. Quase todas as 61 publicações encontradas tratam de técnicas de LCC, no entanto, algumas

¹ <http://www.ieeexplore.ieee.org>

delas utilizam imagens de aviões ou de satélites do tipo radar, e por este motivo não foram selecionadas. Outra parte das publicações limita-se à comparação de técnicas já exploradas, e por este motivo também não foram selecionadas. Além disso, algumas publicações foram excluídas por não apresentarem algum tipo de experimento e não fornecerem os dados estabelecidos no protocolo. Ao final, restaram 15 publicações, cujos dados são apresentados no Quadro 3.

Quadro 3. Extração dos dados

Ano	Autor(es)	Satélite/Sensor	RE* (m)	n*	Classificador(es)	AG* (%)
2010	Dai	LANDSAT-5 TM	30	4	<i>Particle Swarm Optimization;</i> <i>Ant Colony Optimization</i>	98,59
2010	Dai e Liu	CBERS CCD	19	4	<i>Support Vector Machine;</i> <i>Maximum Likelihood; Decision</i> <i>Tree; Artificial Neural Network;</i> <i>Spectral Angle Mapper;</i> <i>Minimum Distance</i>	93,43
2010	Xu, Yang e Liang	ALOS	10	6	<i>Improved Random Decision</i> <i>Trees</i>	87,53
2010	Ye <i>et al.</i>	MODIS (NDVI)	250	6	<i>Support Vector Machine</i>	82,21
2011	Jin <i>et al.</i>	QuickBird	2,4	3	<i>k-Nearest Neighbor</i>	91,58
2011	Li <i>et al.</i>	LANDSAT TM	30	8	<i>Decision Tree</i>	91,50
2011	Stavroukoudis, Theocharis e Zalidis	IKONOS	1;4	13	<i>Boosted Genetic Fuzzy</i> <i>Classifier</i>	72,45
2011	Zhang e Kerekes	WorldView-2	0,5;1,8	2	<i>Self-Organizing Map;</i> <i>Watershed</i>	100,0
				3		80,01
				10		81,59
				10		73,91
2012	Huo <i>et al.</i>	SPOT5	2,5;10	6	<i>Local Softened Affine Hull</i>	85,70
2012	Shimoda e Fukue	MODIS (SR)	500	17	<i>Minimum Distance</i>	99,00
2012	Stavroukoudis <i>et al.</i>	EO-1 HYPERION	30	6	<i>Feature Selective Linguistic</i> <i>Classifier</i>	88,50
2013	Liu <i>et al.</i>	LANDSAT-5 TM	30	6	<i>Support Vector Machine</i>	95,10
2014	Marconcini, Fernandez-Prieto e Buchholz	SPOT-4 HRVIR; ENVISAT ASAR	20	4	<i>Targeted Land-Cover</i>	87,78
		PROBA CHRIS	30	4		97,84
2014	Martins-Bedê <i>et al.</i>	LANDSAT-5 TM	30	6	<i>Multi Space Nearest Neighbors</i>	95,00
2015	Yan e Roy	LANDSAT-7 ETM	30	4	<i>Laplacian Eigenmaps; Spectral</i> <i>Angle Mapper</i>	90,30
				7		84,40
				9		81,50

* RE = Resolução Espacial | n = número de classes em estudo | AG = Acurácia Global

6. Resultados

Dai (2010) propõe um método de LCC baseado na combinação dos algoritmos *Particle Swarm Optimization* e *Ant Colony Optimization*. A acurácia global de 98,59% foi obtida em um experimento que utilizou seis bandas espectrais (1-5;7) do satélite LANDSAT-5 para a classificação de uma região de Pequim (China) em quatro classes de interesse: terra verde, terra urbana, terra nua e água. Dai e Liu (2010) propõem uma abordagem baseada em *voting*, um método para a combinação de classificadores heterogêneos. No experimento, foram utilizadas três (4;3;2) das cinco bandas espectrais da câmera CDD do satélite CBERS para a classificação da cobertura da Terra em Myanmar (um país no sul da Ásia) em água, floresta, terra cultivada e vegetação rasteira.

A proposta de Xu, Yang e Liang (2010) consiste em um algoritmo de árvore de decisão aleatória melhorado, que considera o fator de balanceamento, a impureza dos nós e diferentes tipos de amostras. O experimento é realizado com base em imagens do satélite ALOS sobre Longmen County (China), e classifica a cobertura em da Terra em água, arrozal, vegetação, terreno seco, residencial e estrada. Ye *et al.* (2010) propõem uma técnica que consiste na fusão de séries históricas de imagens através do algoritmo HANTS (*Harmonic ANalysis of Time Series*) e posterior classificação através da Máquina de Vetores de Suporte (SVM, do inglês *Support Vector Machine*). A região estudada compreende toda a bacia de Poyang, o maior lago de água doce na China.

O experimento de Jin *et al.* (2011) utiliza dados do satélite multiespectral de alta resolução QuickBird para classificar a cobertura de uma pequena região de Xian (China) em relva, construção e madeira. A estratégia apresentada pelos autores consiste em incorporar os modelos geoestatísticos exponencial e gaussiano em um classificador k-NN (*k-Nearest Neighbor*) para melhorar a acurácia da LCC. Li *et al.* (2011) apresentam um método que utiliza séries temporais de imagens e diferentes técnicas de classificação para cada uma das 8 coberturas em estudo. A região estudada compreende uma área de 4452 km² localizada em Gaotai County, na China.

Stavrakoudis, Theocharis e Zalidis (2011) propõem o BGFC (*Boosted Genetic Fuzzy Classifier*), um classificador baseado em GFRBCS (*Genetic Fuzzy Rule-Based Classification System*) e projetado sob a abordagem IRL (*Iterative Rule Learning*). Os autores utilizam um pacote de imagem do satélite IKONOS, que fornece uma resolução espacial (RE) de 1 metro no modo pancromático (tons de cinza) e de 4 metros no modo multiespectral. Uma característica que chama atenção neste estudo é a complexidade da LCC (13 classes), realizada sobre a região do lago Koronia, no norte da Grécia.

O WorldView-2, assim como o QuickBird e o IKONOS, é uma proposta de sensoriamento remoto em alta resolução. O satélite fornece imagens com RE de 50 centímetros no modo pancromático (tons de cinza) e 1.8 metros no modo multiespectral (8 bandas). Zhang e Kerekes (2011) utilizam imagens do WorldView-2 para avaliar uma proposta de classificação não-supervisionada baseada na combinação dos algoritmos *Self-Organizing Map* (SOM) e *Watershed*. São realizados experimentos com diferentes quantidades de classes sobre uma área adjacente ao Instituto de Tecnologia Rochester, nos EUA.

Huo *et al.* (2012) propõem uma nova abordagem de classificação, denominada *Local Softened Affine Hull* (LSAH). A região estudada está localizada em Xangai e os

dados obtidos do satélite SPOT 5 incluem dois canais visíveis (verde e vermelho) com RE de 10 metros, um canal próximo ao infravermelho com RE de 10 metros e um canal pancromático com RE de 2,5 metros. Shimoda e Fukue (2012) propõem um algoritmo para classificação da cobertura da terra em escala continental e/ou global com base em séries temporais do produto *Surface-Reflectance* (SR) do sensor MODIS.

Stavarakoudis *et al.* (2012) propõem o *Feature Selective Linguistic Classifier* (FeSLiC), um classificador do tipo *Genetic Fuzzy Rule-Based Classification System* (GFRBCS) com três estágios de aprendizagem. No experimento, são obtidas seis classes de cobertura (*pinus brutia*, *pinus nigra*, árvores de folha caduca, outras vegetações, áreas não vegetadas e água) da ilha de Tasos (Grécia) através dos dados do sensor hiperespectral HYPERION, que fornece um total de 242 bandas espectrais.

Liu *et al.* (2013) propõem um modelo SVM semi-supervisionado, denominado PS3VM, que utiliza os algoritmos *Self-Adaptive Mutation-Particle Swarm Optimization* e *Gustafson-Kessel Fuzzy Clustering*. A acurácia global de 95,10% foi obtida em um experimento que utilizou seis bandas espectrais (1-5;7) do satélite LANDSAT-5 para a classificação da cobertura de uma região do distrito de Yanji (China) em água, campos agrícolas, área residencial e três tipos de florestas.

Marconcini, Fernandez-Prieto e Buchholz (2014) propõem uma técnica para a identificação de classes de cobertura da terra de interesse específico. O experimento teve como alvo a identificação de quatro tipos de cobertura (milho, água, cevada de inverno, e trigo de inverno) em duas diferentes regiões da Terra: a primeira em Demmin (Alemanha), utilizando imagens dos sensores SPOT-4 HRVIR e ENVISAT ASAR, e a segunda em Barrax (Espanha), utilizando imagens do sensor PROBA CHRIS.

Martins-Bedê *et al.* (2014) propõem um algoritmo de classificação denominado ms-NN (*Multi Space Nearest Neighbors*), uma extensão do algoritmo k-NN (*k-Nearest Neighbor*). No último estudo, Yan e Roy (2015) fazem um refinamento no algoritmo *Laplacian Eigenmaps* (LE) não-linear para aplicação em dados de satélite multi-temporais com grandes proporções de dados em falta.

7. Conclusões

Em relação à pergunta de pesquisa formulada no tópico 5.1, os resultados apresentados no tópico 6 permitem identificar como principais técnicas para a classificação de dados de sensores multiespectrais e/ou hiperespectrais: (i) fusão de dados de diferentes faixas espectrais, sensores e/ou datas; (ii) desenvolvimento, aperfeiçoamento e/ou combinação de algoritmos de classificação.

Marconcini, Fernandez-Prieto e Buchholz (2014) aplicam a técnica de LCC proposta sobre diferentes dados de entrada. Yan e Roy (2015) e Zhang e Kerekes (2011), por sua vez, aplicam a técnica proposta utilizando diferentes quantidades de classes. A grande variação das acurácias globais obtidas nesses experimentos demonstra que as características das imagens utilizadas (região em estudo, sensor, resolução espacial) e a complexidade da classificação são variáveis que podem exercer grande interferência nos resultados de um classificador.

Assim, torna-se limitada a análise comparativa, em termos de acurácia global, das técnicas propostas no Quadro 1, tendo em vista que cada experimento está inserido

em um cenário com características bastante distintas. Como solução, sugere-se que seja estabelecida uma base de dados comum, para que novos estudos possam aplicar e comparar o desempenho de diferentes técnicas de LCC.

Um aspecto que pode ser verificado nos resultados da revisão, é a ausência de experimentos que utilizem uma técnica para a classificação de um mesmo conjunto de coberturas em diferentes regiões da Terra. Assim, novos estudos podem ter seus esforços voltados para identificação de melhores técnicas de classificação de coberturas específicas (TLCC - *Target Land Cover Classification*), utilizando para tal, imagens de diferentes locais com coberturas semelhantes. As informações a serem fornecidas por esses estudos podem ser úteis para o desenvolvimento de classificadores especialistas, capazes de reconhecer determinados tipos de cobertura com alto grau de precisão.

Referências

- Dai, Q. (2010). "A hybrid PSO/ACO algorithm for land cover classification". In *Proceedings of 2nd International Conference on Information Science and Engineering (ICISE2010)*, pages 3428-3430.
- Dai, L. and Liu, C. (2010). "Multiple classifier combination for land cover classification of remote sensing image". In *Proceedings of 2nd International Conference on Information Science and Engineering (ICISE2010)*, pages 3835-3839.
- Giri, C. (2012). "Remote sensing of land use and land cover: principles and applications". Boca Raton: CRC Press, 2012.
- Gomez-Chova, L. *et al.* (2015). "Multimodal Classification of Remote Sensing Images: A Review and Future Directions". In *Proceedings of the IEEE*, v. 103, Issue 9, pages 1560-1584.
- Gonzalez, R. C. and Woods, R. E. (2010). "Processamento digital de imagens". 3. ed. São Paulo: Pearson Prentice Hall, 2010.
- Huo, H. *et al.* (2012). "Land Cover Classification Using Local Softened Affine Hull". In *Ieee Transactions on Geoscience and Remote Sensing*, v. 50, Issue 11, pages 4369-4383.
- Jin, Z. *et al.* (2011). "The geographical weighted K-NN classifiers in land cover classification from remote sensing image: A case study of a subregion of Xi'an, China". In *Proceedings of 19th International Conference on Geoinformatics*, pages 1-5.
- Kitchenham, B. and Charters, S. (2007). "Guidelines for performing systematic literature reviews in software engineering". Technical Report EBSE 2007-001, Keele University and Durham University Joint Report.
- Li, H. *et al.* (2011). "A Study on the Land Cover Classification of Arid Region Based on Multi-temporal TM Images". In *Proceedings of 3rd International Conference on Environmental Science and Information Application Technology (ESIAT 2011)*, pages 2406-2412
- Liu, Y. *et al.* (2013). "A self-trained semisupervised SVM approach to the remote sensing land cover classification". In *Computers & Geosciences*, v. 59, pages 98-107.

- Mahmon, N. A. and Ya'acob, N. (2014). "A review on classification of satellite image using Artificial Neural Network (ANN)". In *Proceedings of IEEE 5th Control and System Graduate Research Colloquium (ICSGRC)*, pages 153-157.
- Marconcini, M., Fernandez-Prieto, D. and Buchholz, T. (2014). "Targeted Land-Cover Classification". In *Ieee Transactions on Geoscience and Remote Sensing*, v. 52, Issue 7, pages 4173-4193.
- Martins-Bedê, F. de T. *et al.* (2014). "An application of multiple space nearest neighbor classifier in land cover classification". In *Proceedings of International Geoscience and Remote Sensing Symposium (IGARSS 2014)*, pages 1713-1716.
- Mittal, V., Singh, D. and Saini, L. M. (2014). "A comparative analysis of supervised land cover classification using multi-polarized PALSAR EM image fusion". In *Proceedings of 9th International Conference on Industrial and Information Systems (ICIIS 2014)*, pages 1-5.
- Shimoda, H. and Fukue, K. (2012). "Global land cover classification using MODIS surface reflectance products". In *Proceedings of 7th IAPR Workshop on Pattern Recognition in Remote Sensing (PRRS)*, pages 1-4.
- Shiraishi, T. *et al.* (2014). "Comparative Assessment of Supervised Classifiers for Land Use–Land Cover Classification in a Tropical Region Using Time-Series PALSAR Mosaic Data". In *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 7, Issue 4, pages 1186-1199.
- Song, K. *et al.* (2009). "Land use/land cover (LULC) characterizaitoin with MODIS time series data in the Amu River Basin". In *IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2009)*, v. 4, pages IV-310-IV-313.
- Stavroukoudis, D. G. *et al.* (2012). "A Genetic Fuzzy-Rule-Based Classifier for Land Cover Classification From Hyperspectral Imagery". In *IEEE Transactions on Geoscience and Remote Sensing*, v. 50, Issue 1, pages 130-148.
- Stavroukoudis, D. G., Theocharis, J. B. and Zalidis, G. C. (2011). "A Boosted Genetic Fuzzy Classifier for land cover classification of remote sensing imagery". In *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 66, pages 529-544.
- Xu, H., Yang, M. and Liang, L. (2010). "An improved random decision trees algorithm with application to land cover classification". In *Proceedings of 18th International Conference on Geoinformatics*, pages 4-7.
- Yan, L. and Roy, D. P. (2015). "Improved time series land cover classification by missing-observation-adaptive nonlinear dimensionality reduction". In *Remote Sensing of Environment*, v. 158, pages 478-491.
- Ye, C. *et al.* (2010). "Improving MODIS Land Cover Classification Using NDVI Time-Series and Support Vector Machine in the Poyang Lake Basin, China". In *Proceedings of 6th International Conference on Wireless Communications Networking and Mobile Computing (WiCOM 2010)*, pages 295-304.
- Zhang, J. and Kerekes, J. (2011). "Unsupervised urban land-cover classification using WorldView-2 data and self-organizing maps". In *Proceedings of International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 150-153.