

## Otimização de classificação supervisionada da cobertura do solo em São Leopoldo (RS) por meio de seleção de conjuntos de dados mínimos

Bárbara Maria Giacom Ribeiro <sup>1</sup>  
Jorge Antonio Silva Centeno <sup>2</sup>  
Carlos André Bulhões Mendes <sup>1, 3</sup>

<sup>1,3</sup> UFRGS - Universidade Federal do Rio Grande do Sul

<sup>1,3</sup> PROPUR - Programa de Pós-Graduação em Planejamento Urbano e Regional  
Rua Sarmiento Leite, 320, 5º Andar - 90.050-170 - Porto Alegre, RS, Brasil

<sup>3</sup> IPH - Instituto de Pesquisas Hidráulicas  
Av. Bento Gonçalves, 9500 - 91.501-970 - Porto Alegre, RS, Brasil  
barbara.giaccom@ufrgs.br ; mendes@iph.ufrgs.br

<sup>2</sup> UFPR - Universidade Federal do Paraná  
Setor de Ciências da Terra, Departamento de Geomática  
Caixa Postal 19001, Centro Politécnico - 81.531-990 - Curitiba, PR, Brasil  
centeno@ufpr.br

**Abstract.** Recent developments in geotechnologies have provide resources to propose innovative strategies for urban and environmental management, including remote sensing data and computational resources for processing them, which together, can generate high-quality map products and valuable databases. For the purpose of mapping the Earth's surface, digital image processing and classification enables information extraction through recognition of patterns and objects related to features of interest. The practical use of large volumes of orbital data implies, however, some costs, for example, the computational cost, which is generally high, and is required for data processing and classification. In many cases, one faces a classification problem resulting from non-increase of results' accuracy as the number of bands used (and therefore the amount of information available) increases. One possible solution lies in selecting a subset of features with more discriminating power among the available bands. The aim of this study is to evaluate and compare the performance of land cover classification using a parametric classifier (Maximum Likelihood) using different sets of input data (i.e., number of spectral bands), extracted from two Landsat 8 images (dry × rainy seasons), city of São Leopoldo, Rio Grande do Sul, Brazil. The data sets are defined based on the calculation of the transformed divergence. Finally, the results are analyzed statistically to assess the quality of the classifications.

**Palavras-chave:** sensoriamento remoto, processamento digital de imagens, divergência transformada; remote sensing, digital image processing, transformed divergence.

### 1. Introdução

Informações atualizadas e detalhadas sobre o uso e cobertura do solo são estratégicas para o planejamento e gestão urbana e regional, envolvendo questões relacionadas à expansão e ao adensamento das cidades, às mudanças climáticas e à necessidade de proteção ambiental e conservação da biodiversidade. O uso de sensoriamento remoto em áreas urbanas cresce vertiginosamente, pois os sensores orbitais estão cada vez mais adequados para tais estudos, devido à melhoria nas resoluções espacial, espectral e radiométrica (Ehlers, 2008; Ribeiro; Fonseca, 2013).

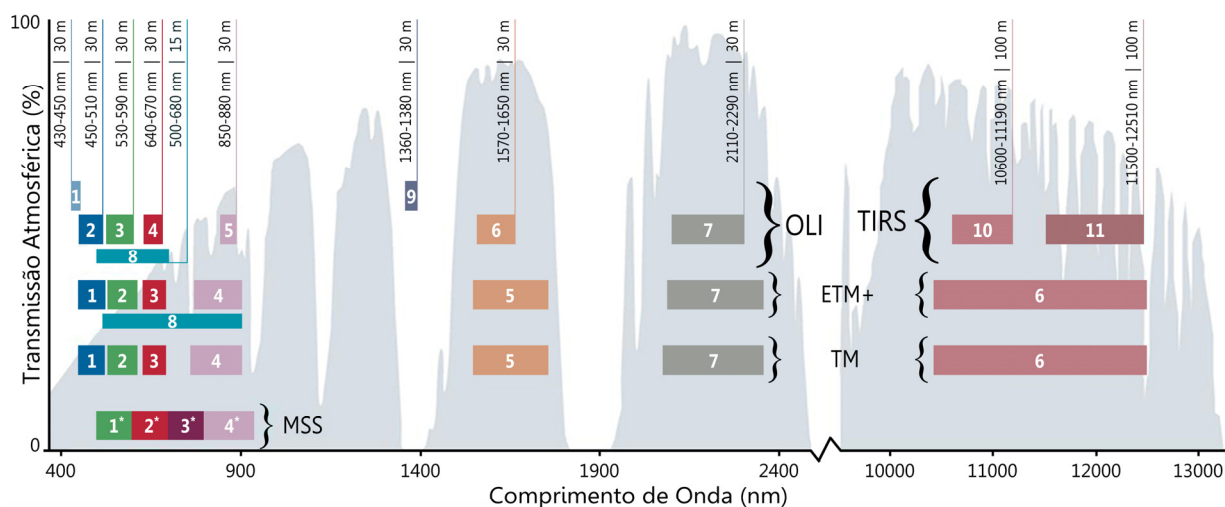
A classificação e o processamento de imagens digitais possibilitam a extração de informações, por meio de reconhecimento de padrões e objetos, para fins de mapeamento da superfície terrestre que correspondem a feições de interesse. O resultado obtido da classificação é uma imagem digital constituída de *pixels* classificados, i.e., de informação categorizada (i.e., um mapa). No entanto, os mapas obtidos através da classificação digital de imagens muitas vezes apresentam erros (e.g., Zhu et al, 2000; Couturier et al, 2007), e consequentemente, incertezas com relação aos resultados e análises derivadas, o que pode conduzir à tomada de decisões inadequada ou equivocada quando do uso de tais produtos. Por exemplo, mapas de cobertura do solo podem apontar taxas irreais de mudança de um ambiente (urbano ou natural),

acarretando, entre outros problemas, em decisões erradas em políticas de gestão territorial.

O objetivo deste estudo é avaliar e comparar o desempenho de classificações de cobertura do solo utilizando um classificador supervisionado paramétrico (Máxima Verossimilhança) utilizando conjuntos de dados de entrada diferentes (i.e., conjunto de bandas espectrais), extraídos de duas imagens Landsat 8, uma de época seca, outra de época chuvosa. Os conjuntos de dados são definidos com base no cálculo da divergência transformada. Por fim, os resultados são analisados estatisticamente para avaliar a qualidade das classificações realizadas.

### 1.1 Sensor Landsat 8

Lançado em fevereiro de 2013, o sensor orbital Landsat 8 dá continuidade ao programa iniciado em 1972. Esse novo satélite trouxe novidades importantes, principalmente com relação à resolução espectral. Os dois novos instrumentos são o sensor espectral OLI (*Operational Land Imager*), que dará continuidade aos produtos gerados a partir dos sensores TM e ETM+, e o sensor termal TIRS (*Thermal Infrared Sensor*). Foram adicionadas duas bandas espectrais: a *coastal* (ou azul profundo) (banda 1), projetada especificamente para os recursos hídricos e investigação da zona costeira, e um novo canal de infravermelho (banda 9), para a detecção de nuvens cirros. Tais adições provocaram mudanças nos intervalos dentro do espectro dos canais de todas as bandas. A partir do sensor termal TIRS, foram criadas duas bandas espectrais para o comprimento de onda antes coberto por uma única banda nos sensores TM e ETM+ (NASA, 2016). Algumas bandas apresentam largura menor no espectro, principalmente as do infravermelho. Na Figura 1, apresentam-se os intervalos espectrais das bandas dos sensores OLI e TIRS do Landsat 8 em comparação com os sensores MSS, TM e ETM+ da família Landsat.



\*As bandas 1 a 4 do sensor MSS correspondem, respectivamente, às bandas 4 a 7 nos Landsats 1, 2 e 3. Os valores de transmissão atmosférica para este gráfico foram calculados utilizando MODTRAN para estação de verão em latitude média e atmosfera nebulosa (cerca de 5 km de visibilidade).  
 Fonte: adaptado de [http://landsat.usgs.gov/images/L8\\_band\\_combos\\_b.jpg](http://landsat.usgs.gov/images/L8_band_combos_b.jpg), 2016

Figura 1. Intervalos espectrais das bandas dos sensores OLI e TIRS / Landsat 8 em comparação com os sensores MSS, TM e ETM+ / Landsat 1 a 7, contrapostos com o gráfico das janelas atmosféricas.

É importante destacar que os novos sensores realizam varredura eletrônica (*pushbroom*), em vez de varredura mecânica (*whiskbroom*), utilizados anteriormente. Sensores *pushbroom* possuem um menor basculamento do satélite devido à organização dos detectores característicos desse tipo de sensor e um menor basculamento da plataforma possibilita uma diminuição no erro de posicionamento das imagens: anteriormente, era da ordem de 60 a 80 metros, indicando uma escala ideal de 1:100.000 ou até menores; as imagens do sensor OLI, deteriam um erro de posicionamento em torno de 12 metros (NASA, 2016).

Outra inovação importante foi quanto à resolução radiométrica. Os sensores OLI e TIRS

proporcionam um melhor desempenho radiométrico, quantificado em uma faixa dinâmica de 12 bits. Essa melhoria possibilita uma maior caracterização de alvos da imagem e podem contribuir para a diminuição do efeito de sombras. Em relação à resolução espacial, o Landsat 8 se assemelha aos seus antecessores: as bandas 1, 2, 3, 4, 5, 6, 7, e 9 possuem uma resolução de 30 metros; as bandas termais 10 e 11 possuem uma resolução de 100 metros; e a banda 8 (pancromática) possui resolução de 15 metros (NASA, 2016). Na Figura 1, também são especificadas as características das bandas dos sensores OLI e TIRS quanto às resoluções espectrais e espaciais. Um bom panorama histórico da missão Landsat 8, bem como uma revisão de estudos utilizando tais dados, pode ser encontrada em Loveland e Irons (2016).

## 2. Material e métodos

A problemática das inundações do Rio dos Sinos no município de São Leopoldo - RS é histórica e acompanha a formação do município. Ao longo das últimas décadas, as inundações têm provocado impactos negativos para a economia, com elevados prejuízos financeiros e problemas sociais, em especial, das áreas urbanas localizadas na planície de inundação (Bazzan, 2011). Por se tratar de uma região próxima a jusante do rio dos Sinos, possui maior propensão a enchentes, já que recebe todo o volume de água drenado das sub-bacias à montante (e.g., Oliveira et al., 2009). De acordo com o levantamento de desastres naturais ocorridos entre 1980 e 2005 (Reckziegel, 2007), as inundações estão entre os eventos com maior número de ocorrências no Rio Grande do Sul, com destaque para o município de São Leopoldo, com mais de 20 ocorrências de desastres desencadeados por enchentes.

O conhecimento do comportamento dos corpos hídricos em períodos de precipitação elevada pode ser de fundamental importância ao evitar perda de vidas humanas e prejuízos financeiros (Bazzan, 2011). Desse modo, o sensoriamento remoto oferece importantes recursos para o mapeamento de recursos hídricos e do monitoramento das dinâmicas de água de superfície (Tucci; Mendes, 2006).

### 2.1. Área de Estudo

A área de estudo é constituída pelo município de São Leopoldo, localizado na região leste do estado do Rio Grande do Sul, na Região Metropolitana de Porto Alegre (Figura 2). O município está inserido na bacia hidrográfica do rio dos Sinos, sendo cortado pelo rio, na região do baixo rio dos Sinos, a cerca de 20 km de sua foz.

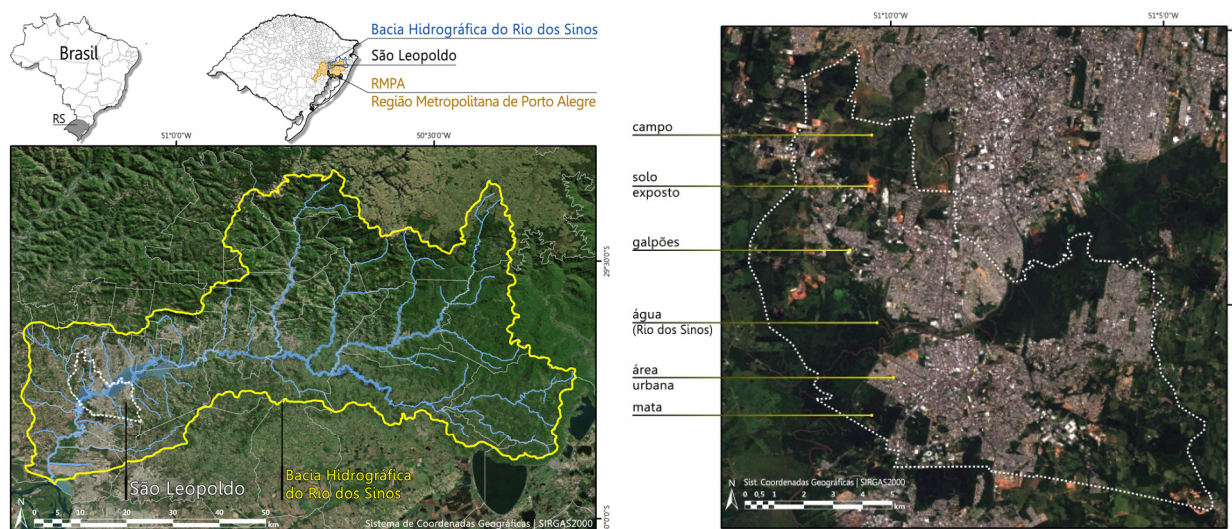


Figura 2. Localização da área de estudo (município de São Leopoldo) e seu contexto na Bacia do Rio dos Sinos; destaque para indicação de exemplos de ocorrência das classes de cobertura do solo definidas para o mapeamento.

Com área de 102,7 km<sup>2</sup>, o município possui uma população estimada em 228.370 habitantes em 2015 (IBGE, 2016). As ocupações que ocorrem na planície do rio dos Sinos, em geral, apresentam baixo padrão urbanístico e se encontram nas zonas mais fragilizadas, ficando mais expostas a riscos ambientais, neste caso, pelas inundações que ocorrem na região de influência do rio dos Sinos entre os municípios de São Leopoldo e Campo Bom.

## 2.2. Dados de Entrada

Neste trabalho, os seguintes dados foram utilizados: duas imagens do sensor Landsat 8, compostas pelas 11 bandas adquiridas pelos sensores OLI e TIRS, coletadas em 24/01/2015 e em 20/10/2014, correspondendo às épocas mais seca (janeiro) e mais chuvosa (outubro). Ambas foram adquiridas no Nadir; embora o horário de coleta seja o mesmo (10h18min horário local), os dados de iluminação são: azimute de 78,91° e 58,64°, elevação de 56,77° e 57,44°, e distância Terra-Sol de 0,9843935 e 0,9957772 unidades astronômicas, respectivamente.

As imagens Landsat 8 são disponibilizadas gratuitamente por meio da plataforma *Earth Explorer* (<http://earthexplorer.usgs.gov/>) do Serviço Geológico Americano (*United States Geological Survey* - USGS), onde só podem ser adquiridas no modo ortorretificado.

## 2.3. Metodologia

Os passos metodológicos podem ser divididos em três etapas: pré-processamento, processamento e pós-processamento, que são detalhadas na sequência. As etapas de processamento e pós-processamento foram realizadas utilizando-se o *software* livre MultiSpec v.3.1 (Purdue Research Foundation, 2007).

Na etapa de pré-processamento, os passos foram realizados de modo independente para cada uma das imagens (24/01/2015 e 20/10/2014). Inicialmente, as onze imagens das bandas sensores OLI e TIRS foram acumuladas (*layer stacking*) para compor uma única imagem. Nos casos das bandas 8 (15 m), 10 e 11 (100 m), foi realizada a reamostragem para mesma resolução das demais bandas (30 m), utilizando o algoritmo do vizinho mais próximo. Em seguida, as imagens foram recortadas utilizando-se um polígono (em dado vetorial) do município de São Leopoldo (IBGE, 2011).

A etapa de processamento iniciou-se com a análise de cada imagem por meio da definição das classes de cobertura do solo e com a posterior coleta de amostras de treinamento e de teste para cada uma das classes estabelecidas. As amostras de treinamento são utilizadas para extrair informações e caracterizar cada classe, fornecendo informações para o classificador supervisionado que analisará a imagem; as amostras de teste são utilizadas na etapa pós-processamento para verificação da qualidade da classificação produzida. A qualidade das amostras é fundamental para a caracterização correta das classes e para se obter um bom desempenho nas classificações supervisionadas. Para analisar a qualidade estatística das classes calculadas a partir das amostras de treinamento, buscando-se verificar se as classes encontram-se bem definidas ou se existe confusão entre algumas delas, após a coleta das amostras, procedeu-se com a análise da separabilidade das classes de cobertura do solo estabelecidas, com base nas assinaturas espectrais construídas a partir do conjunto de amostras de cada classe e considerando-se cada conjunto possível de dados (i.e., bandas espectrais) (Centeno, 2009).

A confusão entre as classes pode ser avaliada por meio da análise da distância espectral entre as médias, por meio do gráfico de espalhamento das classes, ou ainda, por meio da distância euclidiana entre as classes, calculada a partir de uma matriz de similaridade, entre outros (Centeno, 2009). Um método que considera a variação dos valores coletados em cada classe é o uso da divergência (Swain; Davis, 1978), que utiliza como medida de separabilidade um par de distribuições de probabilidade (Richards; Jia, 2006). Para os dados de sensoriamento remoto, sabe-se que as distribuições normais multidimensionais têm modelado de forma aceitável a distribuição dos dados. Desta forma, pode-se dizer que este método utiliza os vetores

de médias, bem como as matrizes variância-covariância de cada classe, sendo tais valores estimados a partir das amostras. Quanto maior for o valor da divergência, maior será a separabilidade entre as classes (Centeno, 2009). Entretanto, os valores da divergência podem ser calculados apenas para pares de classes. No caso de uma classificação envolvendo mais classes faz-se necessário um critério para avaliar a separabilidade global das amostras, que é obtido calculando-se a média da **divergência transformada** para o conjunto.

$$D_{A,B}^T = 2(1 - e^{-\frac{d_{A,B}}{8}}) \quad (1)$$

$$d_{A,B} = \left\{ \frac{1}{2} Tr [ (\Sigma_A - \Sigma_B)(\Sigma_A^{-1} - \Sigma_B^{-1}) ] \right\} + \left\{ \frac{1}{2} Tr [ (\Sigma_A^{-1} + \Sigma_B^{-1})(m_A - m_B)(m_A - m_B)^t ] \right\} \quad (2)$$

onde:  $D_{A,B}^T$  = divergência transformada;  $d_{A,B}$  = distância entre a classe  $a$  e  $b$ ;  $\Sigma_A$  e  $\Sigma_B$  = matrizes de variância-covariância;  $m_A$  e  $m_B$  = médias das classes  $a$  e  $b$ ;  $Tr$  = traço da matriz, calculado a partir do somatório ao longo de sua diagonal principal.

Neste estudo, é aplicado o método da divergência transformada (DT), que tem mostrado melhores resultados do que métodos como a distância Bhattacharaya e divergência, sendo este o método mais utilizado em estudos em que realizam classificação por Máxima Verossimilhança (Maussel et al., 1990). Os valores obtidos através do cálculo do intervalo separabilidade variam entre 0 e 2.000, e o valor de 2.000 representa a separabilidade máxima entre pares de classes. Além de verificar a boa caracterização das classes por meio das amostras coletadas, a divergência também pode ser utilizada como um indicador da escolha adequada das bandas, i.e., para verificar se o conjunto de bandas selecionadas (juntamente com as amostras) é suficiente para separar as classes espectralmente (Centeno, 2009). Este procedimento aumenta a eficiência computacional, pois descarta do processo de classificação os dados redundantes do conjunto. Desta forma, procedeu-se com a análise da divergência para todas as combinações de bandas para então se escolher aquela que atingisse o maior valor da divergência com o menor número de bandas.

Definidos os conjuntos de bandas mínimas (i.e., conjunto A, B, C e D, para a imagem de janeiro; e conjunto X e Y, para a imagem de outubro), procedeu-se com a classificação das imagens por Máxima Verossimilhança. Este método baseia-se no princípio de que a classificação errada de um *pixel* particular não tem mais significado do que a classificação errada de qualquer outro *pixel* na imagem (Richards; Jia, 2006). O usuário determina a significância nos erros de atributos especificados para uma classe em comparação a outras, e por isso, deve ser aplicado quando o analista conhece bem a imagem a ser classificada, para que possa definir classes que sejam representativas. A eficácia do método depende, principalmente, de uma precisão razoável da estimativa do vetor médio e da matriz de covariância de toda a classe espectral. Isto depende da quantidade de *pixels* incluídos nas amostras de treinamento. A utilização deste algoritmo implica que as classes sigam uma distribuição normal e multivariada, que define extensões de dados em direções espectrais determinadas. O resultado das classificações são seis mapas temáticos, um para cada conjunto de bandas de cada imagem (i.e., A, B, C e D, e X e Y).

Na fase de pós-processamento é realizada a verificação da qualidade dos resultados obtidos. É calculada a matriz de confusão e índices *Kappa* e *Kappa*-condicional. A partir da matriz de confusão, são calculadas medidas descritivas como a exatidão global do usuário e do produtor. Ao redor do valor de *Kappa* são calculados intervalos de confiança usando a variância da amostra e o fato de que a distribuição estatística do *Kappa* é normalmente assintótica. Desta forma, testa-se a significação estatística do *Kappa* para uma única matriz de confusão, através da variância, a fim de determinar: (i) se o nível de acerto da classificação e os dados de referência são significativamente maior que zero e se a classificação realizada é melhor do que uma classificação aleatória; e (ii) se a diferença entre duas matrizes de confusão é significativa.

### 3. Resultados

Foram definidas seis classes de cobertura do solo para classificação das imagens, a saber: ÁGUA (“natural”, incluindo o Rio dos Sinos), ÁREA URBANA, SOLO EXPOSTO, MATA, CAMPO e GALPÕES. A análise por divergência transformada (DT) acerca da separabilidade das classes apontou os seguintes conjuntos de bandas como suficientes para classificação da cobertura do solo (DT = 2000): para a imagem de janeiro: (A) 1 - 3 - 7, (B) 1 - 4 - 7, (C) 1 - 4 - 6 e (D) 1 - 3 - 6; para a imagem de outubro: (X) 1 - 4 - 5 e (Y) 1 - 4 - 6. Além desses conjuntos, foram obtidos valores máximos (DT = 2000) para conjuntos de três bandas compostos pelas bandas das faixas do termal (b10 e b11); entretanto, descartou-se seu uso, por possuírem resolução espacial (100 m) diferente das demais bandas (30 m). A classificação pela Máxima Verossimilhança resultou em seis mapas de cobertura do solo (A, B, C, D, X e Y). Na Figura 3, são apresentados dois deles.

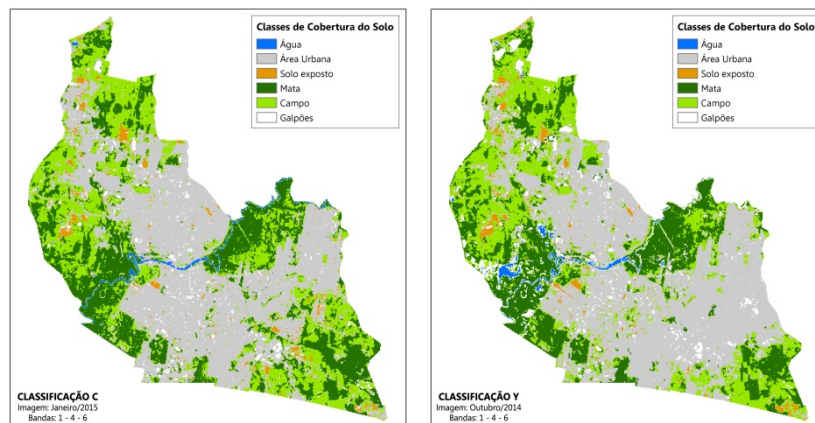


Figura 3. Mapas temáticos resultantes das classificações dos conjuntos de dados: (a) Classificação C, imagem de janeiro; e (b) Classificação Y, imagem de outubro.

A avaliação da qualidade das classificações, com base nas amostras de teste coletadas, é apresentada no Gráfico 1, que mostra as métricas que avaliam os resultados classe-a-classe, a saber: a exatidão do usuário e a do produtor e o índice *Kappa*-condicional.




Gráfico 1. Medidas descritivas classe-a-classe para as seis classificações, sendo as classes de cobertura do solo: 1: ÁGUA, 2: ÁREA URBANA, 3: SOLO EXPOSTO, 4: MATA, 5: CAMPO e 6: GALPÕES; e as medidas descritivas globais: E.G. = exatidão global,  $\kappa$  = índice *Kappa*.

Com base nos dados globais calculados (i.e., exatidão global, índice *Kappa*, erro padrão do *Kappa* e variância do índice *Kappa*), é possível dizer que os resultados obtidos nas seis classificações são excelentes. Entretanto, observa-se que as classificações dos conjuntos de dados referentes ao mês de outubro/2014 (i.e., X e Y) apresentaram pior desempenho do que as classificações referentes ao mês de janeiro/2015. Uma das causas possíveis do pior desempenho pode ser a presença de nuvens na imagem da época chuvosa. Para contornar este problema, pode-se criar uma classe exclusiva para as nuvens ou, ainda, aplicar uma máscara excluindo dos dados de entrada as áreas com nuvens.

A separabilidade das classes de cobertura do solo também pode ser considerada excelente, com destaque para os *pixels* da classe ÁGUA que obtiveram resultados perfeitos em todas as

classificações. Considerando as classificações da imagem da época seca (i.e., A, B, C e D), a classe que apresentou menores índices de acurácia é aquela relativa aos GALPÕES, que foi isolada da classe ÁREA URBANA por representar *pixels* muito claros, com padrão diferente do encontrado na maior parte da área urbana do município em estudo. Os valores mais baixos de exatidão do produtor indicam que o classificador deixou de mapear *pixels* da classe de GALPÕES, ou seja, algumas áreas de Galpões acabaram sendo atribuídas a outras classes, a saber: ÁREA URBANA e SOLO EXPOSTO. Este problema pode se dever tanto à caracterização falha da classe de cobertura, como a confusão nas fronteiras entre os *pixels* de tais classes.

Por sua vez, as classificações dos conjuntos de dados da imagem de época chuvosa (i.e., X e Y) apresentaram piores desempenhos no tocante ao mapeamento da classe CAMPO, que apresentou grande quantidade de *pixels* sendo classificada na classe MATA. Novamente, uma melhor seleção das amostras de treinamento pode ser capaz de solucionar este problema, caracterizando melhor ambas as classes de cobertura do solo.

A análise visual dos mapas permite perceber que há diferenças entre os resultados para as mesmas datas (i.e.,  $A \times B \times C \times D$  e  $X \times Y$ ). O cômputo das áreas mapeadas em cada classe de cobertura é distinto para cada mapeamento. Entretanto, a avaliação estatística dos resultados em pares indicou que os mapas temáticos produzidos a partir das imagens de janeiro (A, B, C e D) não são significativamente diferentes entre si, para um intervalo de confiança de 95%, uma vez que os valores resultantes foram menores que 1,96 ( $\alpha = 5\%$ ) e não podem confirmar as hipóteses de diferença significativa entre as classificações. Já a avaliação estatística dos resultados relativos aos dados de outubro (X e Y) confirma a hipótese de que são significativamente diferentes entre si.

#### 4. Conclusão

Classificando a cobertura do solo do município de São Leopoldo, RS, com imagens Landsat 8 da época chuvosa (outubro/2014) e da época seca (janeiro/2015), este estudo teve como o objetivo principal avaliar e comparar o desempenho de classificações utilizando conjuntos de dados de entrada diferentes (i.e., conjunto de bandas espectrais), que foram definidos com base no cálculo da divergência transformada. Desta forma, foram criados quatro conjuntos de dados (i.e., A, B, C e D) e, conseqüentemente, quatro mapas, para a época seca (i.e., janeiro), e dois conjuntos (i.e., X e Y) para a época chuvosa (i.e., outubro).

O foco do trabalho foi avaliar o mapeamento das áreas relativas ao Rio dos Sinos, fonte de benesses naturais e econômicas, mas também, fonte de preocupação devido às inundações, cada vez mais constantes, ao longo das últimas décadas. As inundações vêm provocando impactos negativos para a economia, com elevados prejuízos financeiros e problemas sociais, em especial, nas áreas urbanas localizadas na planície de inundação. A utilização de um classificador supervisionado paramétrico (i.e., Máxima Verossimilhança) demandou a utilização de amostras de treinamento do algoritmo. Além disso, foram coletadas amostras de teste para posterior verificação da qualidade dos produtos obtidos.

A avaliação dos resultados mostra que as classificações apresentaram excelente desempenho, com altos índices de acurácia global e índice *Kappa*, bem como com ótimo desempenho quando avaliadas cada classe de cobertura do solo (i.e., por meio da exatidão do usuário e produtor e do índice *Kappa*-Condiciona). A confusão entre algumas classes pode ser reduzida com seleção de mais amostras de treinamento ou do refinamento do conjunto de amostras já coletado. Além disso, atribui-se o menor desempenho geral nas classificações da imagem da época chuvosa à ocorrência de nuvens em alguns locais da cena.

Desta forma, conclui-se que a metodologia ora apresentada comprova a viabilidade de realização de classificações semiautomáticas de imagens de sensoriamento remoto otimizando-se processos por meio da redução de dados necessários para discernimento das classes de interesse no mapeamento. Além disso, há que se enfatizar a alta qualidade dos

dados de entrada utilizados, provenientes dos sensores do satélite Landsat 8.

### Agradecimentos

Os autores agradecem à CAPES - Coordenação de Aperfeiçoamento de Pessoal de Nível Superior pelo apoio financeiro à execução deste trabalho sob forma de bolsa de doutorado da primeira autora.

### Referências Bibliográficas

- Bazzan, T. **Mapeamento das áreas com risco de inundação do rio dos Sinos no município de São Leopoldo, RS.** Porto Alegre, 2011. 135 p. Dissertação (Mestrado). Universidade Federal do Rio Grande do Sul - UFRGS. Instituto de Geociências - IGEO. Prog. de Pós-Graduação em Geografia - PPGea, Porto Alegre, RS: UFRGS, 2011.
- Centeno, J. A. S. **Sensoriamento Remoto e Processamento de Imagens Digitais.** Curitiba: Editora do Curso de Pós-Graduação em Ciências Geodésicas, Universidade Federal do Paraná, 2009. 219 p.
- Couturier, S.; Mas, J.-F.; Vega, A.; Tapia, V. *Accuracy assessment of land cover maps in sub-tropical countries: a sampling design for the Mexican National Forest Inventory.* **Online Journal of Earth Sciences**, v. 1, n. 3, p. 127-135. 2007. DOI: ojesci.2007.127.135.
- Ehlers, M. *Sensoriamento remoto para usuários de SIG - Sistemas sensores e métodos: entre as exigências do usuário e a realidade.* In: Blaschke, T.; Kux, H. (eds.) **Sensoriamento Remoto e SIG Avançados - novos sistemas sensores: métodos inovadores.** 2. ed. São Paulo: Oficina de Textos, 2007. 303 p. Cap. 2, p. 19-38.
- IBGE - Instituto Brasileiro de Geografia e Estatística. **Cidades. Rio Grande do Sul - São Leopoldo. População estimada 2015.** Rio de Janeiro: IBGE, 2016. Disponível em: <<http://www.ibge.gov.br/cidadesat/topwindow.htm?1>>. Acesso: 07 jul 2016.
- \_\_\_\_\_. **Censo Demográfico 2010: Resultados do Universo por Setor Censitário.** Rio de Janeiro: IBGE, 2011. Revisão de 02/22/2013. Disponível em: <[geoftp://geoftp.ibge.gov.br/Censos/Censo\\_Demografico\\_2010/Resultados\\_do\\_Universo/Agregados\\_por\\_Setores\\_Censitarios/](http://geoftp://geoftp.ibge.gov.br/Censos/Censo_Demografico_2010/Resultados_do_Universo/Agregados_por_Setores_Censitarios/)>. Acessado em: 25 abr 2013.
- Loveland, T. R.; Irons, J.R. *Landsat 8: The plans, the reality, and the legacy.* **Remote Sensing of Environment**, v. 185, p. 1-6, nov 2016. DOI: 10.1016/j.rse.2016.07.033.
- Mausel, P. W.; Kramber, W. J.; Lee, J. K. *Optimum band selection for supervised classification of multispectral data.* **Photogrammetric Engineering and Remote Sensing**, v. 56, n. 1, p. 55-60. 1990.
- NASA - National Aeronautics and Space Administration. **Landsat 8. Landsat Data Continuity Mission.** 2016. Disponível em: <[http://landsat.gsfc.nasa.gov/?page\\_id=4071](http://landsat.gsfc.nasa.gov/?page_id=4071)>. Acessado em: 2 jul 2016.
- Oliveira, G. G.; Penteado, A. F.; Saldanha, D. L.; Ross, J. L. S. *Mapeamento e análise da distribuição das áreas inundáveis na Bacia do Rio dos Sinos/RS.* In: XIV Simpósio Brasileiro de Sensoriamento Remoto - XIV SBSR, 25-30 abr 2009, Natal, Brasil. **Anais...** São José dos Campos: INPE, 2009. p. 4173-4180.
- Purdue Research Foundation. **MultiSpec - Windows 95/98/NT Version 3.1.** 2007.
- Reckziegel, B. W. **Levantamento dos Desastres desencadeados por Eventos Naturais Adversos no Estado do Rio Grande do Sul no Período de 1980 a 2005.** Santa Maria, 2007. 284 p. Dissertação (Mestrado). Univ. Federal de Santa Maria. Centro de Ciências Naturais e Exatas. Prog. Pós-Graduação em Geografia. S. Maria: UFSM, 2007.
- Ribeiro, B. M. G.; Fonseca, L. M. G. *Urban Land Cover Classification using WorldView-2 Images and C4.5 Algorithm.* In: Joint Urban Remote Sensing Symposium - JURSE 2013, São Paulo, 21-23 de abril de 2013. **Proceedings...** Piscataway: IEEE, 2013. p. 250-253. DOI: 10.1109/JURSE.2013.6550712.
- Richards, J. A.; Jia, X. **Remote sensing digital image analysis - an introduction.** 4. ed. Berlim, Alemanha: Springer-Verlag, 2006. 456 p.
- Swain, P. H.; Davis, S. M. **Remote Sensing: The Quantitative Approach.** New York, EUA: McGraw-Hill International Book Co., 1978. 405 p.
- Tucci, C. E. M.; Mendes, C. A. B. **Avaliação Ambiental Integrada de Bacias Hidrográficas.** Projeto de Instrumentos de Gestão Ambiental (PROGESTÃO). Programa de Proteção e Melhoria da Qualidade Ambiental (PQA) 2. ed. Brasília, DF: Ministério do Meio Ambiente (MMA), 2006. 302 p.
- Zhu, Z. L.; Yang, L. M.; Stehman, S. V.; Czaplowski, R. L. *Accuracy assessment for the U.S. Geological Survey Regional Land-Cover Mapping Program: New York and New Jersey Region.* **Photogrammetric Engineering and Remote Sensing**, v. 66, p. 1425-1435. 2000.