Comparação de métodos de classificação OBIA, Máxima Verossimilhança e Distância Mínima em imagem OLI/Landsat-8 em área de alta diversidade de uso do solo.

Daniel Cohenca[1]
Raquel Carvalho[2]

[1] Universidade Federal de Santa Catarina - UFSC
Departamento de Geociências - Centro de Filosofia e Ciências Humanas - CFH
Campus universitário, SN, Trindade – CEP 88010-970 - Florianópolis - SC, Brasil
dcohenca1@gmail.com

[2] Instituto Nacional de Pesquisas Espaciais – INPE
Centro de Ciências do Sistema Terrestre
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
raquel.carvalho@inpe.br

Abstract. The great demand for reliable thematic maps requires testing different methods of classification to determine the most appropriate considering land use diversity, research objectives, satellite images available and time invested. To identify the most appropriate classification method for an OLI/Landsat-8 satellite image covering a coastal region in Santa Catarina state, Brazil, three methods were tested for their accuracy: Maximum Likelihood and Minimum Distance, pixel based supervised classifications, and Object Based Image Analysis (OBIA) based on image segmentation into regions and separation of classes based on geometric, textural and spectral values. The accuracy assessment for each classification method was based in a stratified random independent sampling to build an error matrix for the global and conditional (per class) Kappa coefficients calculation. In agreement with our results, the maximum likelihood and OBIA classifiers had a better performance in comparison to Minimum Distance method. By other hand, the poorest performance of the Minimum Distance method suggests that the use of spectral mean value only to classify single pixels is not appropriate to the classification process. Although differences of Global Kappa coefficients between OBIA and MaxVer methods were not significant, the assessment of conditional Kappa coefficients for each class evidenced significant differences. Structural differences between these two methods are discussed regarding the achieved results and also on the considerations around time-consuming efforts of an interpreter in the case of OBIA.

Palavras-chave: Classificação de imagem, OBIA, Máxima Verossimilhança, Distância Mínima, OLI/Landsat-8, Coeficiente Kappa, Exatidão.

1. Introdução

A grande demanda por mapas temáticos produzidos a partir de classificação de imagens, torna a análise comparativa de métodos de classificação um tema de investigação importante em diversas linhas de pesquisa e gestão dos recursos naturais (Lu e Weng, 2007; Blanchske, 2010; Rozenstein e Karnieli, 2011; Szuster et al., 2011). Em particular nas zonas costeiras tropicais, onde mudanças intensas resultam em alta diversidade de usos do solo, a produção de mapas temáticos adequados são ferramentas necessárias para definição de estratégias de proteção e manejo de ecossistemas cada vez mais ameaçados (Krause et al., 2004; Szuster et al., 2011).

Nas duas últimas décadas muitos avanços foram alcançados quanto às abordagens e técnicas para melhorar a precisão e qualidade da classificação de imagens (Blachske et al. 2000; Lu e Weng, 2007; Cogalton e Green, 2009; Blanchske, 2010; Korting et al, 2014). No entanto, a produção de mapas temáticos confiáveis é ainda um processo complexo e desafiador, já que muitos fatores como a complexidade da paisagem, a seleção dos dados de sensoriamento remoto, o processamento das imagens e a escolha das abordagens de classificação mais adequadas interferem na qualidade do produto final (Lu e Weng, 2007).

A imprecisão na classificação de imagens advém de diversos fatores incluindo georreferenciamento incorreto, correção atmosférica incompleta e inadequação das amostras

em classificações supervisionadas e não separação de classes parecidas. Considerando que nenhum método de classificação é perfeito, a análise de métodos em função de unidades de paisagem e imageadores específicos, é fundamental para assegurar a confiabilidade de um mapeamento temático (Cogalton e Green, 2009).

Embora o uso de imagens de alta resolução espacial possa detalhar a classificação em áreas de alta complexidade de uso do solo, em especial sobre áreas urbanas (Moran, 2010), a indisponibilidade desses dados em séries temporais maiores, alto custo e limitada extensão espacial torna as imagens LandSat o instrumento mais adequado para os estudos de evolução multitemporal da cobertura do solo em áreas extensas (Rozenstein e Karnielli, 2011; Colditz et al. 2011).

Neste sentido, como etapa preliminar na produção de mapas temáticos, o presente trabalho tem como objetivo desenvolver uma análise comparativa de três métodos de classificação de imagens OLI/Landsat-8 para uma área costeira de alta diversidade de uso do solo.

2. Metodologia de Trabalho.

2.1. Área de estudo. A área de estudo inclui os municípios de Passo de Torres e Balneário Gaivota na zona costeira sul do estado de Santa Catarina, totalizando 25.030 hectares (Figura 1). A elevação na área é homogênea, variando entre 0 e 20 metros do nível do mar em quase toda região.

A área é inteiramente composta de planície sedimentar litorânea holocênica (Diehl e Horn, 1996), originalmente recoberta por restingas herbáceas (fixadora de dunas ou de banhados), arbustivas ou arbóreas (Falkenberg,1999; Conama, 1999). Além desta vegetação nativa, a área inclui alta diversidade de usos do solo incluindo agricultura familiar, monocultura de espécies madeireiras (cultivo de Pinus e Eucalipto), rizicultura, pecuária e diversos núcleos urbanos em vários estágios de ocupação.

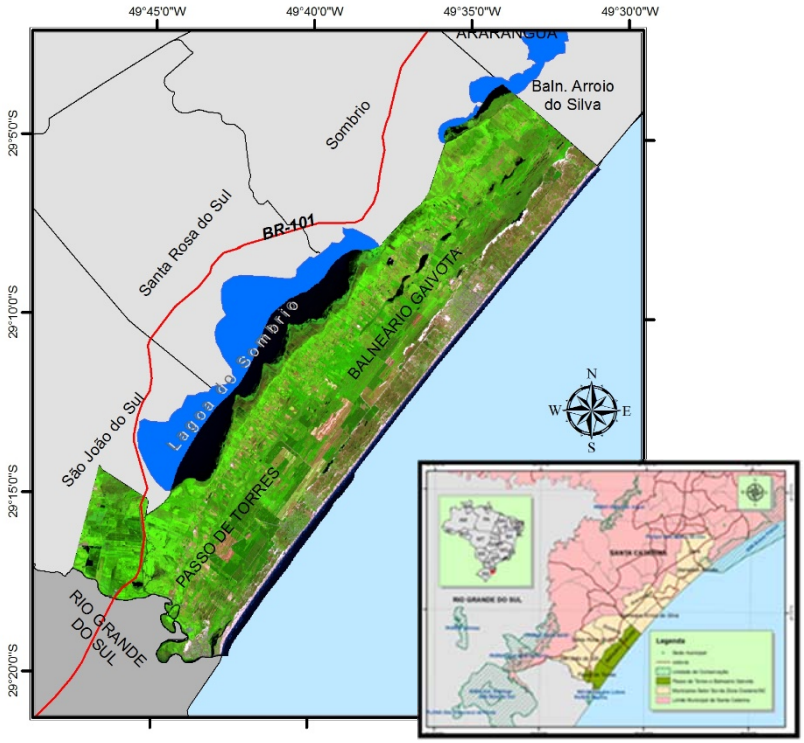

Figura 1. Carta imagem dos municípios de Passo de Torres e Balneário Gaivota. Composição RGB nas bandas 654. Imagem OLI/Landsat-8 220_080 de 30/01/2014 (Limites Municipais: IBGE, 2014)

2.2. Definição das classes. A partir de visitas a campo e análise de imagens de alta resolução, o esquema de classificação definido incluiu onze classes temáticas que caracterizam a diversidade de usos da área (Tabela 1).

Tabela 1. Classes definidas para área de estudo.

Classe	Descrição
Mar	Mar
Agua_Int	Rios e Lagoas;
Duna	Praias e Dunas móveis (Dunas não vegetada);
Rest_Fix	Restinga Herbácea Fixadora de Dunas (Dunas Litorâneas Vegetadas)
Rest_Ban	Restinga Herbácea de lagunas, banhados e baixadas (CONAMA 1999)
Flor_Nativa	Restinga Arbórea (ou Mata de Restinga) em estágios de sucessão médio, avançados ou primária (CONAMA 1999)
Agricultura	Agricultura Familiar diversificada em pequenas propriedades rurais
Rizicultura	Cultivo de Arroz Irrigado
Pastagem	Extensas pastagens com misturas de campos nativos e pastagens plantadas
Pinus_Eucal	Áreas de Reflorestamento de espécies exóticas de Pinus e Eucalipto destinados ao uso madeireiro.
Urbana	Núcleos urbanos em diversos graus de ocupação.

2.3. Imagem utilizada para classificação. A imagem utilizada foi do sensor *Operational Land Imager* (OLI) a bordo do satélite LandSat 8, órbita 220, ponto 080, imageada em 30/01/2014, adquirida através do sítio da United States Geological Survey (USGS, 2014). Para a classificação foram utilizadas seis bandas espectrais de resolução de 30 metros nos comprimentos de onda conforme Tabela 2. As bandas foram compostas e a imagem resultado foi recortada utilizando-se a feição dos limites municipais da área de estudo (Figura 1).

Tabela 2. Comprimentos de onda das seis bandas espectrais utilizadas (USGS, 2014)

OLI/Landsat-8 - Bandas	Comprimento de onda (micrômetros)
Band 2 – Blue	0.45 – 0.51
Band 3 – Green	0.53 – 0.59
Band 4 – Red	0.64 – 0.67
Band 5 – Near Infrared (NIR)	0.85 – 0.88
Band 6 – SWIR 1	1.57 – 1.65
Band 7 – SWIR 2	2.11 – 2.29

2.4. Métodos de classificação. Os métodos de classificação comparados foram (1) Classificação supervisionada Máxima Verossimilhança (MaxVer), (2) Classificação supervisionada por Distância Mínima (MinDist) e (3) Classificação Orientada por Objetos (OBIA), sendo utilizados dois softwares distintos ENVI 5.0 e eCognition 9.0.

As amostras para classificação foram definidas a partir do conhecimento prévio da área e obtidas em áreas amostrais semelhantes, sendo que para as classificações MaxVer e MinDist foram utilizadas as mesmas amostras.

Para cada um dos métodos o esquema de classificação foi "mutuamente exclusivo" (designação de uma única classe por área) e "totalmente exaustivo" (classificação de toda a imagem) (Congalton e Green, 2009).

A classificação supervisionada MaxVer é um método pixel a pixel que assume que a estatística para cada classe em cada banda possui distribuição normal baseada nas amostras coletadas pelo analista e assim calcula a probabilidade do pixel pertencer a uma determinada classe, finalmente atribuindo-lhe o valor onde esta probabilidade é a maior (máxima) (Richards e Jia, 2006). Na classificação supervisionada MinDist para cada pixel é designada uma classe em função da sua maior proximidade em relação unicamente a média do valor dos pixels nas

amostras de treinamento. Estes métodos de classificação foram executados com uso do software ENVI 5.0 nas funções de classificação supervisionada *Maximum Likelihood* e *Minimum Distance*.

Com objetivo de diminuir o efeito de pixels isolados, foi empregada também a ferramenta de pós-classificação *Clump Classes* que aglutina as áreas classificadas adjacentes, utilizando-se um operador morfológico de 3 por 3 pixels para substituição do valor da classificação de pixels isolados (Exelis Visual Informations, 2012) (Figura 2).

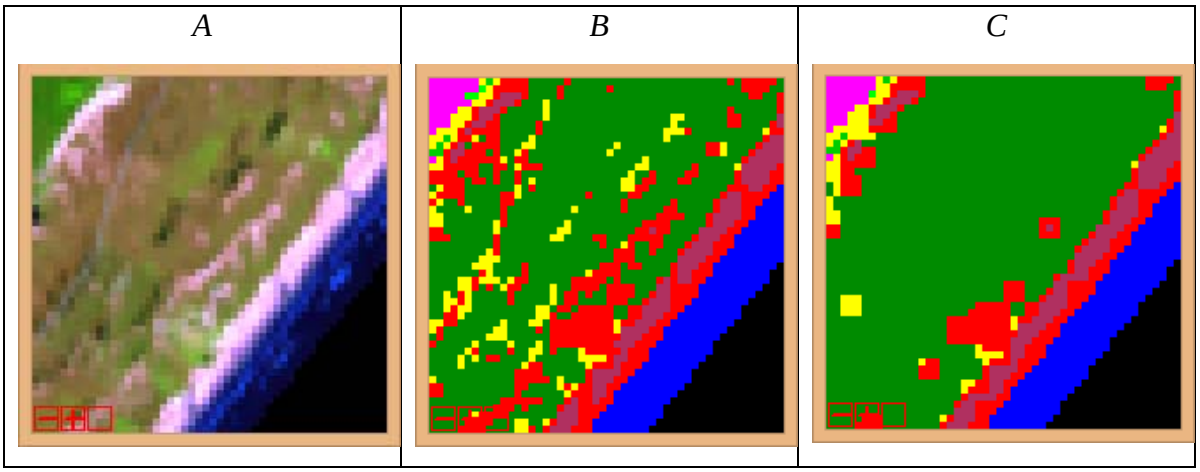

Figura 2. Uso da ferramenta de pós-classificação *Clump classes.* (A) Imagem na Composição de bandas R6G5B4; (B) Imagem classificada MaxVer e (C) Pós-classificação *Clump classes*.

No método OBIA, a classificação de imagens pressupõe conhecimento prévio do interprete sobre a área que, seguindo uma árvore de processos, decide sobre cada passo na diferenciação das classes. O OBIA é um método baseado em objetos oriundos de segmentação da imagem em regiões homogêneas que diminui o nível de detalhe e complexidade da cena, a qual passa a ser formada por objetos (polígonos) com características espectrais médias, geométricas, posicionais e de textura. Para cada objeto é calculado um conjunto de atributos (valores médios de propriedades espectrais dos pixels, relações geométricas e de textura). Cabe ao interprete decidir as regras para definição dos parâmetros que permitem a melhor diferenciação das classes (Francisco e Almeida, 2012).

O método OBIA foi executado no *software* eCognition 9.0 com segmentação em multiresolução, utilizando-se as seis bandas espectrais. Os parâmetros, definidos a partir de comparação visual da melhor relação entre o tamanho das regiões e sua homogeneidade foram: scale 90, shape 0.1, compactness 0.5 (Figura 3).

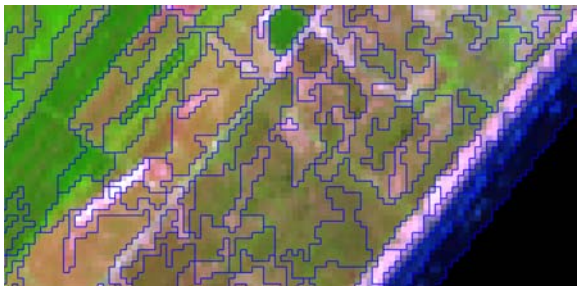

Figura 3. Detalhe de uma área da imagem segmentada por multiresolução nos parâmetros. Composição de bandas R6G5B4.

2.5. Análise dos métodos de classificação. Para efetuar o cálculo de exatidão das classificações inicialmente foi sorteado um conjunto independente de 330 pixels para cada uma das classificações, pelo método de amostragem aleatória estratificada, garantindo a representação

significativa e ponderada de todas as classes da imagem e excluindo previamente as áreas onde foram obtidas as amostras de treinamento dos métodos supervisionados (Foody, 2004; Richards e Jia, 2006).

A classe de referência em cada amostra foi obtida com uso de imagens *RapidEye* de alta resolução espacial, definida visualmente pelo interprete com base na imagem e conhecimento prévio da região, sem consulta simultânea às imagens classificadas.

Para medir e comparar mapas temáticos gerados nas classificações de imagens o coeficiente Kappa é utilizado por ser uma técnica de análise multivariada discreta eficaz (Congalton e Green, 2009).

Para cada um dos métodos de classificação, foi elaborada uma matriz de erro e a partir dela calculados os índices de Exatidão Global (razão entre o somatório do total de acertos da classificação e o total de amostras de referência) e os coeficientes Kappa Global e Condicional de cada classificação.

Os resultados foram comparados aplicando-se teste Z (Foody, 2004; Congalton e Green, 2009), onde a significância da diferença entre dois mapas com diferentes coeficientes Kappa pode ser avaliada pelo desvio da curva normal:

$$Z = \frac{\hat{\kappa}_1 - \hat{\kappa}_2}{\hat{\sigma}^2_{\kappa_1} + \hat{\sigma}^2_{\kappa_2}}$$

Onde: $\hat{k}_1$ – kappa da matriz 1; $\hat{k}_2$ – kappa da matriz 2;
- soma da variância dos coeficientes kappa da matriz 1 e 2

O teste de significância estatística seguiu a hipótese nula onde, com intervalo de confiança de 5%, $|Z|>1,96$ para considerar as classificações significativamente diferentes. (Foody, 2004; Congalton e Green, 2009)

Para interpretação e discussão dos resultados obtidos no coeficiente Kappa utilizou-se o nível de concordância proposto por Galparsoro e Fernández (2001) disposto na Tabela 3.

Tabela 3. Valoração do coeficiente Kappa em níveis de concordância.

Valor de Kappa	Nível de Concordância
< 0.20	Pobre
0.21 – 0.40	Fraca
0.41 – 0.60	Moderada
0.61 – 0.80	Boa
0.81 – 1.00	Muito Boa

3. Resultados e Discussão.

A classificação por MaxVer e OBIA obtiveram os maiores coeficientes Kappa e de exatidão global. Mesmo com coeficientes Kappa de 0.57 (MaxVer) e 0,53 (OBIA) (Tabela 4), no teste de hipótese a diferença entre os resultados obtidos entre estes dois métodos não foi considerada estatisticamente significativa (Tabela 5).

No caso do método MinDist, mesmo utilizando-se as mesmas amostras de classificação supervisionada, o coeficiente Kappa de 0,39 indica que esse método foi significativamente menos preciso que os métodos MaxVer e OBIA (tabelas 4 e 5). A diferença entre os métodos MaxVer e MinDist é que no primeiro são utilizadas a média e covariância dos valores espectrais dos pixels das amostras, enquanto no segundo é utilizada apenas a média. Como resultado já é esperado desempenho superior do método MaxVer (Richards e Jia, 2006).

Segundo Galparsoro e Fernández (2001), classificações que geram coeficientes Kappa entre 0,21 e 0,40 podem ser consideradas fracas, enquanto valores entre 0,41 a 0,60 podem ser considerados moderados. Neste sentido, os métodos de MaxVer e OBIA puderam ser considerados os mais adequados na produção de mapas temáticos para a área em questão.

Ainda que a análise de exatidão com base nos coeficientes globais seja um bom indicador da adequação de métodos específicos a determinados objetivos da classificação, é importante

também considerar as diferenças entre os métodos com respeito ao seu desempenho para classes específicas.

Tabela 4. Exatidão global, Kappa global e Kappa condicional para cada método de classificação:

	Coeficientes Globais		Kappa Condicional por Classe										
Método	Exatidão Global	Kappa Global	Mar	Agua_Int	Duna	Rest_Fix	Rest_Ban	Flor_Nativa	Agricultura	Rizicultura	Pastagem	Pinus_Eucal	Urbana
MaxVer	0.61	0.57	0.90	0.96	0.64	0.42	0.56	0.67	0.29	0.73	0.74	0.52	0.14
MinDist	0.45	0.39	0.95	0.85	0.53	0.58	0.24	0.10	0.12	0.01	0.67	0.39	0.24
OBIA	0.57	0.53	1.00	0.89	0.79	0.59	0.31	0.23	0.33	0.11	0.57	0.62	0.62

Tabela 5. Comparação estatística de significância entre os coeficientes Kappa obtidos nos três métodos.

Método 1	Método 2	|Z|	Significância da Diferença a IC=5%
MaxVer	MinDist	4.31	Sim, |Z|>1.96
MaxVer	OBIA	-1.07	Não, |Z|<1.96
OBIA	MinDist	3.17	Sim, |Z|>1.96

Os coeficientes Kappa condicionais para as classes *Mar* e *Agua_int,* obtiveram valores maiores que 0.81 em todos os três métodos de classificação, desempenho que pode ser considerado muito bom.

O método MaxVer obteve Kappa condicional considerado bom (0,61<K<0,80) para as classes de *Pastagem, Rizicultura, Flor_Nativa e Duna*, moderado (0,41<K<0,60) para as classes *Rest_Ban, Pinus_Eucal e Rest_Fix,* fraco (0,21<K<0,40) para a classe *Agricultura* e pobre (K<0,20) para a classe *Urbana.* (K<0,20).

Já o método OBIA apresentou Kappa condicional considerado bom (0,61<K<0,80) para a classe *Duna*, moderado (0,41<K<0,60) para as classes *Pinus_Eucal, Urbana, Rest_Fix e Pastagens* e fraco (0,21<K<0,40) para as classes *Agricultura, Rest_Ban e Flor_Nativa* e classe *Rizicultura* (K<0,20).

Entre os métodos MaxVer e OBIA, diferenças significativas foram encontradas na separação das classes *Rest_Ban (* |Z|=1.985), *Flor_Nativa (* |Z|=3.483), *Rizicultura (* |Z|=5.511 e *Urbana* (|Z|=4.560).

Algumas destas diferenças podem ser explicadas pela estrutura conceitual de cada método de classificação. Por exemplo, na classe *Urbana*, que na imagem OLI/Landsat-8 compõe-se de objetos variados com característica de textura bem diferenciáveis das outras classes e pixels com alta variância entre si, é gerada muita confusão no método MaxVer enquanto no método OBIA estas mesmas características ajudam na distinção da classe.

Outro exemplo é a classe *Rizicultura* que, por sua distinção em função das características espectrais, ao considerar seis bandas da imagem, gerou bom coeficiente Kappa Condicional no método MaxVer. No entanto, no método OBIA foi maior a dificuldade em garantir bons parâmetros de separação entre esta classe e as classes de *Rest_Ban* e *Pastagem,* dado que todas as três sofrem alagamentos periódicos.

O método OBIA, altamente dependente do intérprete, demandou esforço de tempo muito maior para determinar parâmetros de diferenciação entre as classes. Nesta região de estudo,

caracterizada por um mosaico de pequenas áreas com diferentes usos do solo, a imagem OLI/Landsat-8 não gerou muitas diferenciações por forma e textura de objetos (diferentemente do que se observa em imagens de alta resolução), e as diferenças espectrais dos objetos foram mais utilizadas. No método MaxVer, no qual a distinção entre as classes é feita computacionalmente, o esforço do interprete ocorre apenas na delimitação dos polígonos amostrais, resultando portanto em um menor esforço de tempo em comparação ao método OBIA.

4. Conclusões.

Considerando os objetivos da classificação de imagens para a área de estudo em questão, o método MaxVer se mostrou mais adequado que o método MinDist. Em termos de custo de tempo envolvido considera-se que os dois métodos são equivalentes, envolvendo apenas a seleção de amostras supervisionadas.

Na comparação entre os métodos MaxVer e OBIA, o investimento, em termos de tempo do intérprete deve ser considerado. Enquanto no método MaxVer o intérprete seleciona as amostras de classificação supervisionada e apenas a característica espectral do pixel é considerada, no OBIA é possível utilizar centenas de elementos para separar as classes, os quais dependem de identificação e escolha pelo intérprete. Desta forma, há possibilidade melhorar a classificação aos poucos, criando novos processos nas classes ainda não separadas adequadamente. Na imagem de média resolução espacial, no entanto, encontrar elementos que diferenciem algumas classes é muito trabalhoso, tornando esse método menos adequado.

A classificação OBIA sempre pode ser melhorada, mas é necessário considerar o investimento necessário em termos de esforço de intérprete.

Agradecimentos

Agradecemos a Gilney Bezerra e Ricardo Dal'Agnol da Silva na preparação deste trabalho.

Referências bibliográficas

BLACHSKE, T.; LANG, S.; LORUP, E. STROBL, J.; ZEIL, P. Object-Oriented Image Processing in an Integrated GIS/Remote Sensing Environment and Perspectives for Environmental Applications. In: CREMERS, A.; GREVE, K. (ed). **Environmental Information for planning, Politics and the Public**. v. 2. Metropolis Verlarg, Marburg, pp. 555 – 570. 2000

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and remote sensing**, v. 65, n.1, p.2-16, 2010.

COLDITZ, R.R.; Schmidt, M.; Conrad, C.; Hansen, M.C.; Dech, S. S. Land cover classification with coarse spatial resolution data to derive continuous and discrete maps for complex regions. **Remote Sensing of Environment**. v. 115, n. 12, p. 53264–3275. 2011.

CONGALTON, R.; GREEN, K. **Assessing the Accuracy of Remotely Sensed Data - Principles and Practices**. Boca Raton: CRC Press, Taylor & Francis Group, 2009. 183 p.

DIEH, F.L.; HORN FILHO, N. O., 1996. Compartimentação geológico-geomorfológica da zona litorânea e planície costeira do estado de Santa Catarina. **Notas Técnicas,** vol. 9, pp. 39-50.

EXELIS VISUAL INFORMATIONS. **ENVI 5.0 Help**. 2012.

FALKENBERG, D. de B. Aspectos da flora e da vegetação secundária da restinga de Santa Catarina, sul do Brasil. **Insula**, v. 28, n. 1, p. 1-30, 1999.

FOODY, G.M. Thematic map comparison: evaluating the statistical significance of differences in classification accuracy. **Photogrammetric Engineering & Remote Sensing.** v.70, n. 5, p. 627–633, 2004.

FRANCISCO, C. N.; ALMEIDA, C. M. Interpretação de imagens orbitais por meio de sistema especialista para mapeamento e cobertura da terra em região montanhosa. **Sociedade e Natureza**, v. 24, n. 2, p. 283-302, 2012.

GALPARSORO, L.; FERNÁNDEZ, S.P. **Medidas de concordância: el índice Kappa**. 2010. Disponível em: <http://www.fisterra.com/mbe/investiga/kappa/kappa.htm>. Acesso em: 25 dez. 2014.

KORTING, T. S.; FONSECA, L. M. G.; CASTEJON, E.F.; NAMIKAWA, L. M. Improvements in sample selection methods for image classification. **Remote Sensing**, v. 6, n.8, p. 7580-7591. 2014

KRAUSE, G; BOCK, M; WEIERS, S. BRAUN, G. Mapping Land-Cover and Mangrove Structures with Remote Sensing Techniques: A Contribution to a Synoptic GIS in Support of Coastal Management in North Brazil. **Environmental Management** v. 34, n. 3, p. 429 - 440, 2004.

LU, D.; WENG, Q. A survey of image classification methods and techniques for improving classification performance. **International Journal of Remote Sensin**g, v. 28, n. 5, p. 823-870, 2007.

MORAN, F.E. Land cover classification in a complex urban-rural landscape with quickbird imagery. **Photogramm Eng Remote Sensing**. v. 76, n.10, p. 1159 – 1168, 2010.

PEREIRA, R.M.F.A. Formação sócio-espacial do litoral de Santa Catarina (Brasil): gênese e transformações recentes. **Geosul,** v. 18, n. 35, p. 99-129. 2003.

RESOLUÇÃO CONAMA nº 261, de 30 de junho de 1999, Publicada no DOU no 146, de 2 de agosto de 1999, Seção 1, páginas 29-31.

RICHARDS, J.A.; JIA, X. **Remote Sensing Digital Image Analysis: An Introduction.** Springer, 2006.

ROZENSTEIN, O.; KARNIELI, A. Comparison of methods for land-use classification incorporating remote sensing and GIS inputs. **Apllied Geography**, v. 31, n. 2, p. 533- 544, 2011.

SZUSTER, B.W.; CHEN, Q.; BORGER, M. A comparison of classification techniques to support land cover and land use analysis in tropical coastal zones. **Applied Geography** v. 31, n. 2, p. 525- 532, 2011.

USGS - EarthExplorer. 2014 (Disponível em: http://earthexplorer.usgs.gov) (Acesso em: 25/10/2014.)