

Potencial dos dados Sentinel-2 e Landsat-8 para a classificação do uso e cobertura da terra de um ambiente costeiro

Camile Sothe¹
Cláudia Maria de Almeida¹
Marcos Benedito Schimalski²
Veraldo Liesenberg²

1 Instituto Nacional de Pesquisas Espaciais (INPE). Divisão de Sensoriamento Remoto (DSR). Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil.
camile.sothe@inpe.br; almeida@dsr.inpe.br

2 Universidade do Estado de Santa Catarina (UDESC). Centro de Ciências Agroveterinárias (CAV), Av. Luiz de Camões, 2090, 88520-000 - Lages - SC, Brasil.
a2mbs@udesc.br; veraldo@gmail.com

Abstract. Considering the provision of timely, and accurate data from remote sensing system, satellite images are important source of creating land cover/use information. This study assessed the performance of the Sentinel-2 and Landsat-8 data for classification of a subtropical coastal zone. Two approaches were compared: maximum likelihood (MAXVER) and random forest (RF). Sentinel-2 data resulted in Kappa index 0.97 and 0.94 with MAXVER and RF classifier, respectively, while Landsat-8 Kappa index were 0.92 and 0.90. All methods differed significantly from one another, indicating that the use of Sentinel-2 satellite images had superior results to Landsat-8. The analysis of the variables relevance with RF classifier showed that the new bands of Sentinel-2, like red-edge and near infrared plateau, were decisive for the successful classification of Sentinel-2 data. Additional research is needed to assess the full potential of Sentinel-2 data and to explore potential applications of this data in other environments or land cover change monitoring.

Palavras-chave: remote sensing, random forest, maximum likelihood, sensoriamento remoto, florestas randômicas, máxima verossimilhança.

1. Introdução

O litoral brasileiro é a região de maior ocupação humana do país, com 26,6% da população residindo nessa área (IBGE, 2011). A região costeira recebeu impactos negativos crescentes ao longo de seu histórico de ocupação no país, resultando em ecossistemas altamente degradados (Fundação SOS Mata Atlântica e INPE, 2015). Por ser uma região tão dinâmica, o mapeamento periódico desses locais pode fornecer informações valiosas para auxiliar na conservação e monitoramento de ecossistemas costeiros.

Nas últimas décadas, observou-se uma notável evolução das tecnologias espaciais destinadas ao monitoramento terrestre. Têm-se também novas técnicas para lidar com esses dados, de forma a semiautomatizar o processo da classificação do uso e cobertura da terra. A alta resolução espacial, aliada a um razoável número de bandas espectrais e periodicidade na obtenção de informações, faz com que o advento da nova geração de satélites possibilite uma acurada classificação e monitoramento contínuo do uso e cobertura da terra em nível global. Há 40 anos, dados Landsat fornecem valiosos conjuntos de dados para o monitoramento e mapeamento da superfície terrestre (Zhu et al., 2015). O satélite Landsat-8, lançado em 2013, aprimorou ainda mais essa capacidade, com novas bandas espectrais no azul, no infravermelho de ondas curtas destinada à detecção de nuvens cirrus, duas novas bandas no termal, melhoramento na performance sinal-ruído do sensor, e ainda melhorias na resolução radiométrica das imagens (Roy et al., 2014). Seu sensor *Operational Land Imager* (OLI) fornece imagens ópticas com 30 m de resolução espacial, oito bandas espectrais e 16 dias de resolução temporal (Topaloglu et al., 2016).

Já o Sentinel-2 é um instrumento superespectral de média resolução espacial da *European Space Agency* (ESA), feito para garantir a continuidade de dados globais do monitoramento da superfície terrestre dos satélites Landsat e SPOT. A missão foi lançada em 2015 e possui um amplo campo de visada (290 km), alta capacidade de revisita (cinco dias, com dois satélites), alta e média resolução espacial (10, 20 e 60 m) e um número de bandas relativamente amplo (13 bandas espectrais) (Drusch et al., 2012).

Neste contexto, o objetivo deste estudo é avaliar e comparar a acurácia da classificação de dados oriundos das novas gerações de satélites Sentinel-2 e Landsat-8 em uma região costeira do estado de Santa Catarina (SC). Duas diferentes abordagens foram adotadas sobre os dados multiespectrais provenientes dos dois satélites: uma paramétrica, com o algoritmo Máxima Verossimilhança (MAXVER), e uma não paramétrica, com o algoritmo Florestas Randômicas (*Random Forest-RF*).

2. Material e Métodos

A área de estudo possui 2.646 km² e abrange a região da grande Florianópolis, capital de SC. A região está inserida no ecossistema denominado Floresta Ombrófila Densa (Klein, 1978), possuindo ainda algumas áreas com vegetação litorânea, como mangue e restinga. O clima é do tipo Cfa de Köppen, subtropical úmido, e a altitude de aproximadamente 15 m (Figura 1).

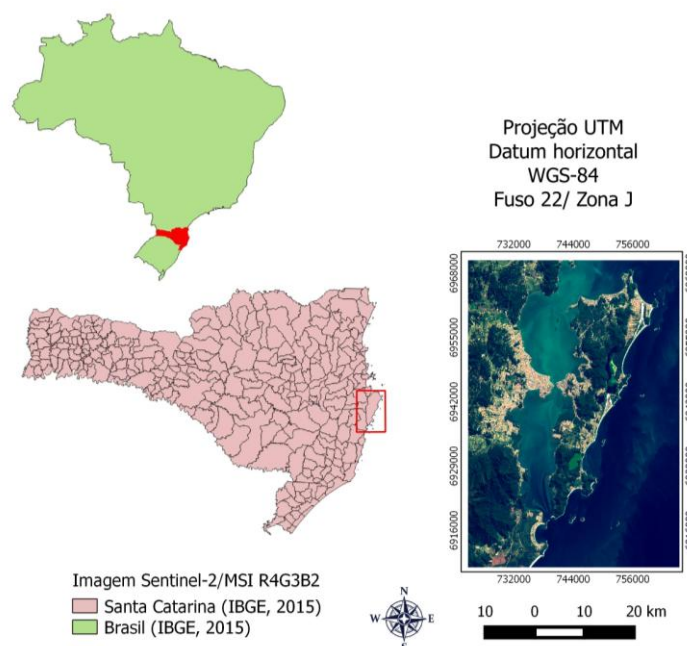


Figura 1. Localização da área de estudo

A cena do sensor OLI do satélite Landsat-8 foi adquirida no site da *United States Geological Survey* (USGS), ortoretificada no nível L1T, órbita/ponto 220/079, datada de 23 de junho de 2016. As bandas espectrais utilizadas no estudo estão discriminadas na Tabela 1. A composição multiespectral de seis bandas foi fusionada com a banda pancromática através do algoritmo *Gram-Schmidt*, a fim de aumentar a resolução espacial das bandas multiespectrais para 15 m.

A cena do sensor *MultiSpectral Instrument* (MSI) da missão Sentinel-2 foi adquirida do site *Land Viewer* (lv.eosda.com), datada de 13 de junho de 2016, com o nível de correção L1C (Tabela 1). Tanto as bandas de 20 m de resolução espacial do Sentinel-2 quanto todas as bandas do Landsat-8 foram reamostradas para 10 m com o interpolador vizinho mais

próximo, para possibilitar as comparações entre elas sem perder o detalhamento da melhor resolução espacial (10 m) das primeiras bandas do Sentinel-2.

As imagens de ambos os sensores foram convertidas para valores de reflectância e corrigidas atmosféricamente com o algoritmo *Quick Atmospheric Correction*, do software ENVI. Destaca-se que as imagens foram adquiridas já corrigidas geometricamente, sendo que as bandas correspondentes a cada cena foram colocadas no sistema de coordenadas *Universal Transform Mercator* (UTM) e *datum* horizontal *World Geodetic System* (WGS- 84, Fuso 22, Zona J).

Tabela 1. Bandas do sensor Landsat-8 OLI e Sentinel-2 MSI utilizadas no estudo.

Landsat-8 (μm)	Descrição	Resolução (m)	MSI Sentinel-2 (μm)	Descrição	Resolução (m)
Banda 2 (0,45-0,51)	Azul	30	Banda 2 (0,458-0,523)	Azul	10
Banda 3 (0,53-0,59)	Verde	30	Banda 3 (0,543-0,578)	Verde	10
Banda 4 (0,64-0,67)	Vermelho	30	Banda 4 (0,650-0,680)	Vermelho	10
Banda 5 (0,85-0,88)	IVP	30	Banda 5 (0,698-0,713)	IV limítrofe-1	20
Banda 6 (1,57-1,65)	SWIR-1	30	Banda 6 (0,733-0,748)	IV limítrofe-2	20
Banda 7 (2,11-2,29)	SWIR-2	30	Banda 7 (0,765-0,785)	IV limítrofe-3	20
Banda 8 (0,50-0,68)	Pancromática	15	Banda 8 (0,785-0,900)	IVP	10
			Banda 8A (0,855-0,875)	Platô do IV	20
			Banda 11 (1,565-1,655)	SWIR-1	20
			Banda 12 (2,100-2,280)	SWIR-2	20

IV: infravermelho; IVP: infravermelho próximo; SWIR: infravermelho de ondas curtas.

As classes de uso e cobertura da terra foram definidas com base no mapeamento do estado de Santa Catarina feito pelo Projeto de Proteção da Mata Atlântica em Santa Catarina (Geoambiente, 2008): “vegetação”, “água”, “campo”, “agricultura”, “urbano”, “mangue”, “restinga” e incluiu-se mais uma classe denominada “areia”. As amostras de treinamento foram coletadas usando dados de referência do aplicativo Google Earth e do levantamento aerofotogramétrico de SC (Engemap, 2012), o qual fornece imagens com 0,39 m de resolução espacial. Foram coletados 17.653 pixels para o treinamento e outros 7.056 pixels para avaliação dos resultados. Destaca-se que foi utilizado o mesmo conjunto de pixels de treinamento para as duas imagens e duas classificações para possibilitar a comparabilidade entre as abordagens.

Em seguida, procedeu-se à classificação das imagens com os algoritmos MAXVER e RF. O classificador paramétrico MAXVER assume que cada classe de interesse possui distribuição normal. Baseia-se na probabilidade de um *pixel* pertencer à determinada classe e leva em conta a variabilidade das classes usando a matriz de covariância (Lu et al., 2014). O RF é uma técnica desenvolvida por Breiman (2001), como forma de melhorar a acurácia de árvores de classificação e de regressão através da combinação de um grande número de subconjuntos aleatórios de árvores. Quando árvores de decisão são utilizadas, cada árvore contribui com um único voto, e a classificação final é determinada pela maioria dos votos de todas as árvores da floresta. As amostras que não são utilizadas no sorteio inicial são chamadas de *out-of-bag* (OOB) e foram utilizadas para estimar erros de classificação e obter o valor de importância das variáveis. O algoritmo RF possui dois parâmetros a serem determinados: número de variáveis (*mtry*) e número de árvores (*ntree*). Atribuiu-se o valor 100 para o número de árvores, enquanto o número de variáveis foi determinado pela raiz quadrada do número total de bandas espectrais usadas no estudo. A abordagem denominada busca por grade (*grid search*), baseada no erro estimado do OOB, foi usada para encontrar a combinação ótima destes dois parâmetros no ENMap-Box (Van der Linden et al., 2015), e posterior classificação da imagem. Este algoritmo também foi utilizado para verificar a

importância das variáveis na classificação. A classificação das imagens empregando o algoritmo RF foi realizada no ENMap-Box, enquanto a classificação com o algoritmo MAXVER foi feita no aplicativo ENVI 5.3.

Por fim, para a avaliação dos resultados, foram geradas matrizes de confusão, a partir do cruzamento de dados de referência com as amostras de validação. A partir das matrizes, foram calculados os seguintes índices: (a) exatidão global (EG); (b) exatidão do produtor, (c) exatidão do usuário; (d) índice Kappa (Congalton e Green, 1999). Realizou-se o teste z para os índices Kappa das classificações com nível de significância de 5%, ou seja, com um intervalo de confiança de 95%. Quando $z > 1,96$, o teste é significativo, rejeita-se a hipótese de nulidade, podendo-se concluir que existe diferença estatística entre as classificações.

3. Resultados e Discussão

A Tabela 2 mostra o resultado das classificações com a imagem do satélite Sentinel-2, a qual alcançou índice Kappa de 0,97 para o algoritmo MAXVER e 0,94 para o RF (Figura 2). A classificação com o algoritmo MAXVER mostrou-se significativamente superior ao RF de acordo com o teste z . Com exceção da classe “água”, o classificador MAXVER apresentou melhores resultados que o RF para todas as classes. Dentre as abordagens estudadas, a classe “restinga” com o algoritmo RF exibiu maior confusão. Esta classe foi erroneamente classificada com “campo”, “agricultura” e “vegetação”, além de ter apresentado pixels das classes “campo” e “agricultura” atribuídas erroneamente a essa classe. Cabe destacar que a classe restinga apresenta uma mistura de respostas espectrais, já que é composta de areia e vegetação esparsa, o que pode ter ocasionado tal confusão.

Tabela 2. Matrizes de confusão resultante da classificação com a imagem Sentinel-2 com os algoritmos MAXVER e RF.

Algoritmo	Classe	Referência (pixels)								Acurácia (%)	
		Água	Campo	Agricultura	Vegetação	Mangue	Restinga	Urbano	Areia	EP	EU
Classificação MAXVER	Água	1170	0	0	0	0	0	0	0	99,15	100
	Campo	0	924	5	0	0	3	0	0	98,4	99,14
	Agricultura	8	2	736	0	32	13	0	0	96,08	93,05
	Vegetação	0	0	0	1008	0	33	0	0	100	96,83
	Mangue	0	0	0	0	758	0	0	0	94,63	100
	Restinga	0	13	2	0	0	1025	0	0	94,91	98,56
	Urbano	2	0	4	0	11	6	708	7	98,61	95,93
	Areia	0	0	19	0	0	0	10	557	98,76	95,05
	Total	1180	939	766	1008	801	1080	718	564	EG	97,59
Classificação RF	Água	1179	0	0	0	0	0	0	0	99,92	100
	Campo	0	916	0	0	0	48	0	0	97,55	95,02
	Agricultura	0	0	697	0	52	47	0	0	90,99	87,56
	Vegetação	1	0	0	1006	0	40	0	0	99,8	96,08
	Mangue	0	0	7	0	745	0	0	0	93,01	99,07
	Restinga	0	23	15	2	0	945	0	0	87,5	95,94
	Urbano	0	0	47	0	4	0	716	82	99,72	84,33
	Areia	0	0	0	0	0	0	2	482	85,46	99,59
	Total	1180	939	766	1008	801	1080	718	564	EG	94,76

EP: exatidão do produtor; EU: Exatidão do usuário; EG: Exatidão Global.

A Tabela 3 mostra os resultados obtidos a partir da classificação da imagem do satélite Landsat-8. A classificação alcançou índice Kappa de 0,92 e 0,90 com os algoritmos MAXVER e RF, respectivamente (Figura 2). Os resultados foram inferiores aos realizados com a imagem Sentinel-2, principalmente para a classe “agricultura”, a qual foi erroneamente atribuída às classes “campo” e “urbano” para ambos os algoritmos e, ainda, para a classe “restinga” com o algoritmo RF. A maior confusão da classe “agricultura” com áreas urbanas

pode ser devido ao fato de áreas agrícolas serem compostas predominantemente por solo exposto, gerando uma resposta espectral semelhante às áreas construídas. Destaca-se que nas classificações com a imagem Sentinel-2, a confusão da classe “agricultura” e “urbano” foi relativamente menor do que com a imagem Landsat-8. Porém, tanto a classe “restinga” quanto a classe “mangue” obtiveram melhores resultados nas classificações utilizando a imagem Landsat-8. Todas as classificações diferiram significativamente entre si de acordo com o teste z. Isso significa que os resultados com a imagem Sentinel-2 foram significativamente superiores àqueles advindos da imagem Landsat-8, demonstrando o potencial dessa nova geração de satélites para estudos de uso e cobertura da terra.

Tabela 3. Matrizes de confusão resultante da classificação com a imagem Landsat-8 com os algoritmos MAXVER e RF.

Algoritmo	Classe	Referência (pixels)								Acurácia (%)	
		Água	Campo	Agricultura	Vegetação	Mangue	Restinga	Urbano	Areia	EP	EU
Classificação MAXVER	Água	1084	0	0	0	0	0	0	0	91,86	100
	Campo	0	936	51	0	0	0	0	0	99,68	94,83
	Agricultura	15	2	656	85	0	0	0	0	85,64	86,54
	Vegetação	0	0	0	757	0	0	0	0	75,1	100
	Mangue	0	0	0	0	793	0	0	0	99	100
	Restinga	0	1	0	0	8	1080	0	0	100	99,17
	Urbano	0	0	59	138	0	0	714	5	99,44	77,95
	Areia	81	0	0	28	0	0	4	559	99,11	83,18
	Total	1180	939	766	1008	801	1080	718	564	EG	93,24
Classificação RF	Água	1166	0	0	0	0	0	0	0	98,81	100
	Campo	0	925	66	4	0	4	0	0	98,51	92,59
	Agricultura	0	14	482	20	0	2	0	0	62,92	93,05
	Vegetação	0	0	0	757	4	32	0	0	75,1	95,46
	Mangue	0	0	0	0	797	0	0	0	99,5	100
	Restinga	0	0	43	126	0	1042	0	0	96,48	86,04
	Urbano	0	0	175	80	0	0	703	15	97,91	72,25
	Areia	14	0	0	21	0	0	15	549	97,34	91,65
	Total	1180	939	766	1008	801	1080	718	564	EG	91

EP: exatidão do produtor; EU: Exatidão do usuário; EG: Exatidão Global.

Resultados semelhantes foram encontrados por Szuster et al. (2011), que testaram os classificadores MAXVER, redes neurais artificiais (*Artificial Neural Network- ANN*), máquinas de vetor de suporte (*Support Vector Machine- SVM*) na classificação de zonas costeiras tropicais com imagens de média resolução espacial do satélite ASTER. Os autores obtiveram acurácia global de 93,95% para o MAXVER, 94,99% para o ANN e 94,15% para o SVM. Lu et al. (2014) compararam o desempenho dos algoritmos MAXVER, ANN, árvores de decisão, SVM e Análise Baseada em Objeto (*Object-Based Image Analysis- OBIA*) em imagens Landsat-5 e ALOS/PALSAR para classificar o estágio sucessional da vegetação no Bioma Amazônia. Os autores concluíram que, quanto aos algoritmos utilizados, o desempenho variou conforme o conjunto de dados utilizados, sendo que o MAXVER e árvores de decisão obtiveram melhor desempenho na classificação de imagens Landsat. Topaloglu et al. (2016) compararam o desempenho da classificação semiautomática do uso e cobertura da terra com os algoritmos SVM e MAXVER usando imagens do satélite Sentinel-2 e do satélite Landsat-8. O SVM apresentou desempenho superior ao MAXVER, com acurácia global de 81,7% para imagens Landsat-8 e 84,17% para imagens Sentinel-2. Ambos os classificadores tiveram desempenho superior ao utilizarem imagens do satélite Sentinel-2.

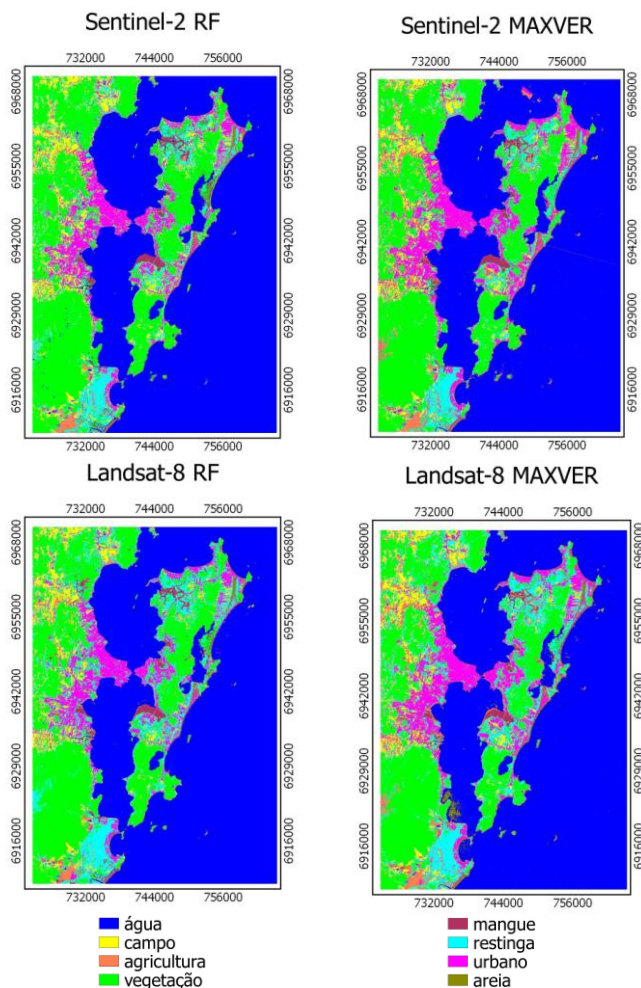


Figura 2. Resultado da classificação do uso e cobertura da terra com os algoritmos MAXVER e RF nas imagens Sentinel-2 e Landsat-8.

O algoritmo RF implementado no ENMap-Box fornece uma medida de importância de cada variável no processo de classificação. A determinação desta medida permitiu a identificação das informações mais relevantes na discriminação das classes de vegetação (Figura 3). Percebe-se que, para a imagem do satélite Sentinel-2, destacaram-se as bandas vermelho, a primeira banda do IV limítrofe (*Red-edge*), a banda situada no platô do IV e ambas as bandas do SWIR. Já para a Landsat-8, as bandas IVP e SWIR 2 apresentaram maior importância que as demais. De uma maneira geral, percebe-se que as faixas espectrais situadas em outras porções do espectro que não sejam do visível trazem valiosas informações na discriminação das classes de uso e cobertura da terra. As bandas presentes no Sentinel-2, como a IV limítrofe e IV platô, podem ter sido cruciais para os melhores resultados alcançados com os testes com essas imagens em relação à Landsat-8. Alguns estudos mostraram que a incorporação da banda vermelho limítrofe nas imagens RapidEye, por exemplo, por ser sensível ao teor de clorofila das plantas, aumentou a separabilidade das classes de uso da terra (Schuster et al., 2012; Adam et al., 2014) e, conseqüentemente, melhorou a acurácia da classificação das classes vegetação e agricultura nesses estudos.




Figura 3. Valor de importância das bandas espectrais para a classificação das imagens com o algoritmo RF.

4. Conclusão

O estudo mostrou que tanto as imagens oriundas do satélite Landsat-8 quanto as do Sentinel-2 têm grande potencial para serem utilizadas no mapeamento de uso e cobertura da terra em ambientes costeiros. Cabe destacar que ambas as classificações feitas com a imagem do Sentinel-2, com Kappa de 0,97 e 0,94, foram significativamente superiores às classificações das imagens Landsat-8, Kappa de 0,92 e 0,90. No entanto, classes relacionadas à vegetação litorânea, como restinga e mangue, foram mais bem classificadas com a imagem Landsat-8.

Quanto aos algoritmos utilizados, verificou-se que as classificações com o MAXVER obtiveram acurácia significativamente superiores ao RF, o que causou certa surpresa, já que se esperava que, por se tratar de um ambiente com maior variabilidade, o algoritmo não paramétrico poderia lidar melhor com a classificação. Porém, cabe destacar que não foram explorados parâmetros do classificador, para o qual se atribuiu o valor padrão de 100 árvores. Também não se explorou a variação no número de amostras de treinamento, o que poderia acarretar mudanças nos resultados obtidos. A quantificação da importância das variáveis obtida pelo algoritmo RF permitiu verificar que bandas espectrais até então só obtidas por sensores hiperespectrais, como as do IV limítrofe e platô do IV, tiveram grande importância na classificação realizada.

O uso de classificadores semiautomáticos, aliados as imagens destinadas ao mapeamento global com as do satélite Sentinel-2 e Landsat-8, permite maior dinamismo na replicação dos resultados para outras áreas de estudo ou, ainda, sobre a mesma área em diferentes datas.

Agradecimentos

Os autores agradecem a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo financiamento concedido.

Referências Bibliográficas

Adam, E.; Mutanga, O.; Odindi, J.; Abdel-Rahman, E. M. Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of random forest and support vector machines classifiers. *International Journal of Remote Sensing*, v. 35, n. 10, p. 3440-3458, 2014.

Breiman, L. Random Forests. *Machine Learning*, v. 45, n. 1, p. 5-32, 2001.

Congalton, R. G. and Green, K. *Assessing the accuracy of remotely sensed data: principles and practices*. New York: Lewis Publishers, 1999.

Drusch, M.; Bello, U. Del; Carlier, S.; Colin, O.; Fernandez, V.; Gascon, F.; Hoersch, B.; Isola, C.; Laberinti, P.; Martimort, P.; Meygret, A.; Spoto, F.; Sy, O.; Marchese, F.; Bargellini, P. Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, v. 120, p. 25-36, 2012.

Engemap Geoinformação. **Relatório de produção final**. Edital de concorrência pública n. 0010/2009. Florianópolis SC, 218 p., 2012.

Fundação SOS Mata Atlântica e INPE. **Atlas dos Remanescentes Florestais da Mata Atlântica: Período 2013-2014**. Relatório Técnico, São Paulo: SOS Mata Atlântica e INPE, 2015.

Geoambiente Sensoriamento Remoto Ltda. PROJETO DE PROTEÇÃO DA MATA ATLÂNTICA EM SANTA CATARINA (PPMA / SC), **Relatório Técnico do Mapeamento Temático Geral do Estado de SC**, São José dos Campos – SP, Agosto 2008, 90p.

IBGE, Instituto Brasileiro de Geografia e Estatística. Sinopse do Censo Demográfico 2010. 2011.

IBGE, Instituto Brasileiro de Geografia e Estatística. **Bases Cartográficas 2015**. Disponível em <<http://mapas.ibge.gov.br/bases-e-referenciais/bases-cartograficas/malhas-digitais.html>> Acesso em: 2 de out. de 2016.

Klein, R. M. **Mapa fitogeográfico do Estado de Santa Catarina**. Itajaí: Herbário Barbosa Rodrigues; Florianópolis: Universidade Federal de Santa Catarina, 1978.

Land Viewer. Disponível em: < <https://lv.eosda.com/>> Acesso em: 12 de set. de 2016.

Lu, D.; Li, G.; Moran, E.; Kuang, W. A comparative analysis of approaches for successional vegetation classification in the Brazilian Amazon. **GIScience & Remote Sensing**, v. 51, n. 6, p. 695-709, 2014.

Roy, D. P., Wulder, M. A., Loveland, T. R., Woodcock, C. E., Allen, R. G., Anderson, M. C.; Scambos, T. A. Landsat-8: Science and product vision for terrestrial global change research. **Remote Sensing of Environment**, v. 145, p. 154- 172, 2014.

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, p. 525-532, 2011.

Schuster, C.; Förster, M. ; Kleinschmit., B. “Testing the Red Edge Channel for Improving Land-Use Classifications Based on High-Resolution Multi-Spectral Satellite Data. **International Journal of Remote Sensing**, v. 33, n. 17, p. 5583–5599, 2012.

Topaloglu, R. H.; Sertela, E.; Musaoglu, N. Assessment of classification accuracies of Sentinel-2 and Landsat-8 data for land cover / use mapping. In: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, v. 41-B8, **XXIII ISPRS Congress**, 12–19 July 2016, Prague, Czech Republic, p. 1055-1059, 2016.

United States Geological Survey (USGS). **Landsat Project Description**. Disponível em: <http://landsat.usgs.gov/about_project_descriptions.php> Acesso em: 12 de set. de 2016.

Van der Linden, S.; Rabe, A.; Held, M.; Jakimow, B.; Leitão, P. J.; Okujeni, A.; Schwieder, S. S.; Hostert, P. The EnMAP-Box—A Toolbox and Application Programming Interface for EnMAP Data Processing, **Remote Sens**, v. 7, p. 11249-11266, 2015.

Zhu, Z.; Woodcock, C. E. Continuous change detection and classification of land cover using all available Landsat data. **Remote sensing of Environment**, v. 144, p. 152-171, 2014.