

Análise comparativa de abordagens para classificação do estágio sucessional da vegetação de um fragmento florestal da Mata Atlântica

Camile Sothe¹
Cláudia Maria de Almeida¹
Veraldo Liesenberg²
Marcos Benedito Schimalski²

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.
veraldo@gmail.com; a2mbs@udesc.br

Abstract. The remote classification of the different vegetation successional stages still represents a challenging task in face of the similar spectral response of such classes. This paper is committed to evaluate the performance of both Landsat 8 and RapidEye images in the classification of successional forest stages within a patch of Mixed Ombrophilous Forest located inside the São Joaquim National Park, Santa Catarina State, south of Brazil. Three variables dataset extracted from each image were analyzed, namely; (1) one solely consisting of the spectral bands themselves; (2) a second one comprising GLCM-based texture measures derived from the spectral bands; and (3) a third one containing these two datasets and additionally two vegetation indices obtained from the Landsat-8 image and three vegetation indices from the RapidEye image. Each dataset was subject to three classifiers: random forest (RF), support vector machine (SVM), and maximum likelihood estimation (MLE or MAXVER). Results show that Kappa coefficients ranged from 0.66 to 0.88, and both user's and producer's accuracies were over 50%. The best result was attained with the Landsat 8 image using the third dataset and the RF classifier. Texture measures such as mean, contrast and dissimilarity were decisive for the successful classification of both images.

Palavras-chave: Secondary forests; Support Vector Machine; Random Forest; Textural features.

1. Introdução

O recente avanço das características espaciais e espectrais de sensores orbitais e o melhoramento de algoritmos de classificação de imagens destes sensores têm aumentado a popularidade de dados de Sensoriamento Remoto como fonte para mapeamento do uso e cobertura da terra (Adam et al., 2014). O uso dessas ferramentas deve ser avaliado quantitativa e qualitativamente no mapeamento de remanescentes florestais em concordância com a Lei da Mata Atlântica (Lei 11.428/2006) (Brasil, 2006). No entanto, o mapeamento de estágios de sucessão florestal impõe outros desafios no processo de classificação, pois os espectros de refletância são muito similares (Amaral et al., 2009; Lu et al., 2014). De acordo com Lu et al. (2014), a seleção de variáveis adequadas e o desenvolvimento de algoritmos avançados são os dois principais tópicos de pesquisa visando melhorar o desempenho da classificação da vegetação.

Além da melhoria nas características de dados orbitais fornecidos por satélites como o Landsat-8 e RapidEye, a escolha da técnica de classificação também é determinante para o mapeamento confiável do uso e cobertura da terra. Dentre os algoritmos não-paramétricos, florestas randômicas (*random forest* - RF) e máquinas de vetor de suporte (*support vector machine*- SVM) têm se destacado devido a sua superioridade na tratabilidade das imagens (Adam et al., 2014). Isso inclui a habilidade em sintetizar funções de regressão ou classificação baseadas em conjuntos de dados discretos ou contínuos, menor sensibilidade a ruídos ou *over-training* e capacidade para lidar com conjuntos de dados não-balanceados (Breiman, 2001).

Diante disso, este artigo tem o objetivo de avaliar metodologias para classificação do estágio sucessional da vegetação do Bioma Mata Atlântica, usando imagens de alta resolução espacial do satélite RapidEye e de média resolução espacial do satélite Landsat-8. Os objetivos específicos foram 1) testar o desempenho dos algoritmos por aprendizagem de máquina RF e SVM e compará-los com o classificador máxima verossimilhança (MAXVER), algoritmo paramétrico largamente utilizado (Jensen, 2011); 2) verificar a contribuição de métricas texturais e índices de vegetação provenientes destas imagens na classificação dos estágios sucessionais da vegetação; 3) comparar o desempenho das imagens RapidEye e Landsat-8 para diferenciação das tipologias vegetais.

2. Material e Métodos

A área de estudo abrange 800 ha e situa-se na região central do Parque Nacional de São Joaquim (PNSJ) (Estado de Santa Catarina), a uma altitude ortométrica média de 1.638 m com cobertura florestal constituída de um mosaico de Floresta Ombrófila Mista permeada por Campos de Altitude e Matas Nebulares (Faxina, 2014). O clima é do tipo Cfb de Köppen, mesotérmico úmido sem estação seca definida, verões frescos, com ocorrência de geadas severas e frequentes no inverno, e temperatura média de 12°C. O levantamento em campo da vegetação na área de estudo foi realizado no ano de 2013 por Faxina (2014). A autora definiu o estágio sucessional conforme critérios estabelecidos pela resolução CONAMA nº 04/1994 (Brasil, 1994).

Os dados do estudo compreenderam uma cena do sensor OLI, a bordo do satélite Landsat-8, órbita/ponto 220/080 de 16 de fevereiro de 2014, no site da *United States Geological Survey* (USGS), com correção no nível L1T, e duas cenas 2226120 e 2226121 da constelação de satélites RapidEye, datadas de 27 de setembro de 2013, com correções de nível 3A. Importante ressaltar que apesar de as datas das imagens Landsat-8 e RapidEye serem distintas, não ocorrem diferenças sazonais na fitofisionomia vegetal em estudo. Foi realizada a conversão dos números digitais (ND) das imagens de ambos os satélites para valores físicos de radiância e efetuada a correção atmosférica com o algoritmo *Fast Line-Of-Sight Atmospheric Analysis Of Spectral Hypercubes* (FLAASH). As bandas multiespectrais da cena do satélite Landsat-8 foram fusionadas com a banda pan de 15 m através do algoritmo *Gram-Smith* e reamostradas para a resolução espacial de 5 m com o interpolador vizinho mais próximo.

Após a etapa de pré-processamento, definiram-se as classes e procedeu-se à coleta de amostras. As classes encontradas na área de estudo foram: vegetação em estágio avançado (VEA), vegetação em estágio médio (VEM), vegetação em estágio inicial (VEI), banhado de altitude e campo. A seleção das amostras baseou-se em trabalhos em campo realizados por Faxina (2014) e na fotointerpretação de ortoimagens com resolução espacial de 0,39 m, oriundas do levantamento aerofotogramétrico de Santa Catarina (Engemap, 2012). Foram gerados dois conjuntos de amostras: treinamento e validação, este último não contemplando *pixels* utilizados no treinamento.

Para cada imagem, foram utilizados três grupos de informações distintos, definidos como A1, A2 e A3 nas imagens Landsat-8; e B1, B2 e B3 nas imagens RapidEye (Tabela 1). No primeiro grupo, utilizaram-se somente as bandas espectrais puras de cada sensor (2 a 7 para o sensor OLI e 1 a 5 para o RapidEye). Descartou-se a primeira banda do sensor OLI, *coastal aerosol*, por apresentar muito ruído. O segundo grupo foi composto apenas pelas métricas texturais derivadas das bandas espectrais. Optou-se por utilizar as métricas texturais obtidas a partir da matriz de co-ocorrência dos níveis de cinza (*grey levels co-occurrence matrix - GLCM*), proposta por Haralick et al. (1973). Seis delas são consideradas as mais relevantes para a análise de imagens em sensoriamento remoto: segundo momento angular, contraste, variância, homogeneidade, variância, correlação, entropia (Lu et al., 2014). Além destas seis

métricas citadas, neste estudo também se utilizou a dissimilaridade e a média textural. Escolheu-se o tamanho de janela 9 x 9 *pixels*, já que testes preliminares indicaram ser este o tamanho mais adequado. Pelo mesmo motivo, optou-se pela direção sudoeste e nível de quantização de 64 bits. As medidas texturais foram calculadas para todas as bandas espectrais de cada sensor. O terceiro grupo envolveu todos os dados dos dois grupos anteriores, acrescentados do índice de vegetação por razão simples (RS) e índice vegetação por diferença normalizada (IVDN). Das imagens RapidEye, obteve-se ainda o índice de vegetação por diferença normalizada *red-edge* (IVDNre), composto pelas bandas vermelho limítrofe (*red-edge*) e infravermelho.

Tabela 1. Grupos de variáveis definidos para cada experimento.

Imagem	Grupo	Bandas espectrais	Bandas texturais	Índices de vegetação	Total de bandas
Landsat-8	A1	2 a 7	-	-	6
	A2	-	med, var, hom, con, dis, ent, sec, cor * (bandas 2, 3, 4, 5, 6, e 7)	-	48
	A3	2 a 7	med, var, hom, con, dis, ent, sec, cor * (bandas 2, 3, 4, 5, 6, 7)	RS, IVDN	56
RapidEye	B1	1 a 5	-	-	5
	B2	-	med, var, hom, con, dis, ent, sec, cor * (bandas 1, 2, 3, 4, 5)	-	40
	B3	1 a 5	med, var, hom, con, dis, ent, sec, cor * (bandas 1, 2, 3, 4, 5)	RS, IVDN, IVDNre	48

*med= média textural; var= variância; hom= homogeneidade; con= contraste; dis= dissimilaridade; ent= entropia; sec= Segundo momento angular; cor= correlação.

Cada grupo de variáveis da Tabela 1 foi testado com três classificadores: RF (Breiman 2001), SVM (Cortes e Vapnik, 1995) e MAXVER, sendo as duas primeiras executadas no aplicativo EnMAP-Box (Van der Linden et al., 2015) e a última no 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) acurácia global (AG); (b) acurácia do produtor, (c) acurácia do usuário; (d) índice Kappa (Congalton e Green, 1999). O teste z para os índices Kappa das classificações foi realizado 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 os valores obtidos são significativamente diferentes.

3. Resultados e Discussão

A Tabela 2 mostra a acurácia do produtor e usuário para cada classificador e grupo de variáveis utilizado. Todos os classificadores tiveram bom desempenho, com AG mínimo de 73,3% e índice Kappa de 0,66 no grupo B1 associado ao classificador MAXVER; e máximo de 90,83% e índice Kappa de 0,88 no grupo A3 associado ao classificador RF. As classes referentes aos estádios sucessionais da vegetação mantiveram acurácia de produtor e usuário superiores a 50% com os algoritmos não-paramétricos, ótimos resultados em se tratando de classes espectralmente tão semelhantes.

Nos grupos A1 e B1, constituídos apenas pelas bandas espectrais dos satélites Landsat-8 e RapidEye, respectivamente, os resultados foram semelhantes para os três algoritmos. A AG foi de aproximadamente 86% nas imagens Landsat-8, e 76% nas imagens RapidEye. O pior resultado alcançado foi com o classificador MAXVER e grupo B1, que teve 73% de acurácia. Para os grupos A2 e B2, compostos apenas pelas componentes texturais das bandas espectrais, o algoritmo RF obteve melhor desempenho. Percebeu-se que as informações texturais aumentaram a acurácia da classificação nos classificadores SVM e MAXVER

apenas para a imagem RapidEye. Isso pode estar atrelado ao fato de que imagens RapidEye têm maior resolução espacial, e as medidas texturais suavizaram as sombras da imagem e os ruídos intraclasse. Nos grupos de informações A3 e B3, o classificador RF novamente se destacou em relação aos demais, obtendo acurácia máxima na imagem Landsat-8. Novamente, para os classificadores SVM e MAXVER, apenas nas imagens RapidEye houve aumento da acurácia em comparação ao se utilizar somente as bandas espectrais puras. Percebe-se que o algoritmo RF teve um aumento gradual em sua acurácia com o acréscimo de variáveis, enquanto o SVM e MAXVER se beneficiaram deste acréscimo somente nos experimentos envolvendo as imagens RapidEye. Para as imagens Landsat-8, os classificadores SVM e MAXVER obtiveram melhor desempenho ao se utilizar somente as bandas espectrais puras.

Tabela 2. Acurácia do usuário e do produtor obtida para cada experimento.

RF	Acurácia do usuário (%)					Acurácia do produtor (%)					AG		
	Classes de cobertura da terra					Classes de cobertura da terra							
	VEA	VEM	VEI	Campo	Banhado	VEA	VEM	VEI	Campo	Banhado			
Experimento	A1	88,93	81,12	86,38	86,69	92,64	A1	75,79	89,19	88,04	94,15	82,41	86,18
	A2	95,72	87,71	81,4	86,32	85,66	A2	91,51	89,19	83,73	87,38	84,48	87,73
	A3	95,53	87,76	85,2	90,00	96,23	A3	94,03	91,1	79,9	96,92	87,93	90,83
	B1	57,55	67,2	90,06	90,45	92,06	B1	57,55	71,61	77,99	93,23	87,93	76,95
	B2	80,99	80,75	90,75	97,45	93,38	B2	87,11	82,63	75,12	94,15	97,24	87,48
	B3	82,11	81,95	90,91	97,51	95,92	B3	88,05	83,69	76,56	96,31	97,24	88,60
SVM	Acurácia do usuário (%)					Acurácia do produtor (%)					AG		
	Classes de cobertura da terra					Classes de cobertura da terra							
	VEA	VEM	VEI	Campo	Banhado	VEA	VEM	VEI	Campo	Banhado			
Experimento	A1	85,57	81,87	95,77	87,07	84,75	A1	78,3	85,17	86,6	93,23	86,21	85,81
	A2	87,41	76,46	88,52	63,53	82,02	A2	78,62	86,02	51,67	87,38	64,48	76,52
	A3	89,36	77,01	77,78	65,82	93,66	A3	79,25	83,05	53,59	96	66,21	78,07
	B1	57,87	64,01	91,01	90,18	92,03	B1	42,77	79,87	77,51	93,23	87,59	76,33
	B2	73,54	74,21	90,85	88,48	88,01	B2	75,16	75	71,29	96,92	88,62	81,41
	B3	73,55	73,81	93,14	88,58	97,37	B3	71,7	78,81	77,99	97,85	89,31	83,02
MAXVER	Acurácia do usuário (%)					Acurácia do produtor (%)					AG		
	Classes de cobertura da terra					Classes de cobertura da terra							
	VEA	VEM	VEI	Campo	Banhado	VEA	VEM	VEI	Campo	Banhado			
Experimento	A1	88,02	87,65	68,08	91,28	89,12	A1	92,45	75,21	84,69	90,15	90,34	85,56
	A2	70,5	82,71	76,3	83,15	88,3	A2	88,68	65,89	77,03	92,62	80,69	79,86
	A3	69,85	82,57	77,25	84,85	93,44	A3	89,62	65,25	77,99	94,77	83,45	80,92
	B1	55,13	75,3	82,27	79,84	88,28	B1	81,13	52,97	79,9	91,38	72,76	73,30
	B2	68,87	78,32	100	96,33	96,53	B2	82,08	75	80,38	96,92	95,86	85,25
	B3	70,59	79,21	100	96,43	99,64	B3	83,02	76,69	80,38	99,69	95,86	86,49

Classes: VEA: vegetação em estágio avançado; VEM: vegetação em estágio médio; VEI: Vegetação em estágio inicial.

Quanto aos estádios sucessionais da vegetação, as classes VEA e VEM tiveram melhor resultado com o grupo A3 e classificador RF. A classe VEI alcançou 100% de acurácia do usuário nos experimentos B2 e B3 com o algoritmo MAXVER. Ao analisar o histograma desta classe, percebeu-se que ela mantém maior regularidade na frequência de valores dos

dados de treinamento em todas as bandas. Desta forma, o algoritmo paramétrico foi mais adequado para delimitá-la, já que foi possível computar a variância da classe e as matrizes de covariância. As classes campo e banhado são as que tiveram melhores resultados nos grupos que utilizaram imagem RapidEye, ou seja, B1, B2 e B3. Nos experimentos com as imagens Landsat-8, verificou-se maior confusão entre essas duas classes, o que pode estar associado à menor resolução espacial desta imagem.

Comparando os três estádios sucessionais individualmente, nenhum algoritmo conseguiu melhor acurácia para todas as classes nos diferentes grupos de informações. Os grupos de variáveis A3 e B3 associados ao algoritmo RF produziram os melhores resultados para as classes VEA e VEM. Na classe VEI, os resultados variaram conforme a imagem. Para a imagem Landsat-8, o melhor desempenho foi alcançado com o algoritmo SVM associado ao grupo A1, ao passo que, na imagem RapidEye o algoritmo MAXVER associado aos grupos B2 e B3 teve melhor desempenho.

De maneira geral, a classificação dos estádios sucessionais da vegetação apresentou melhores resultados nos experimentos com a imagem do satélite Landsat-8. A maior resolução radiométrica de imagens do sensor OLI pode ter exercido influência significativa, principalmente na distinção das classes VEA e VEM. De acordo com Jensen (2011), uma alta resolução radiométrica geralmente aumenta a probabilidade de que os fenômenos sejam avaliados com mais exatidão pelo Sensoriamento Remoto. A menor acurácia dos experimentos conduzidos com as imagens dos satélites RapidEye pode ser atribuída à maior variabilidade espectral no interior da mesma classe de cobertura da terra (Adam et al., 2014). Além disso, pode-se considerar a influência de sombras nas classificações da imagem RapidEye, devido à maior resolução espacial. Por estes motivos, abordagens de análise de imagens por regiões ou por objeto (*object based image analysis- OBIA*) poderiam ser exploradas para a classificação deste tipo de imagem.

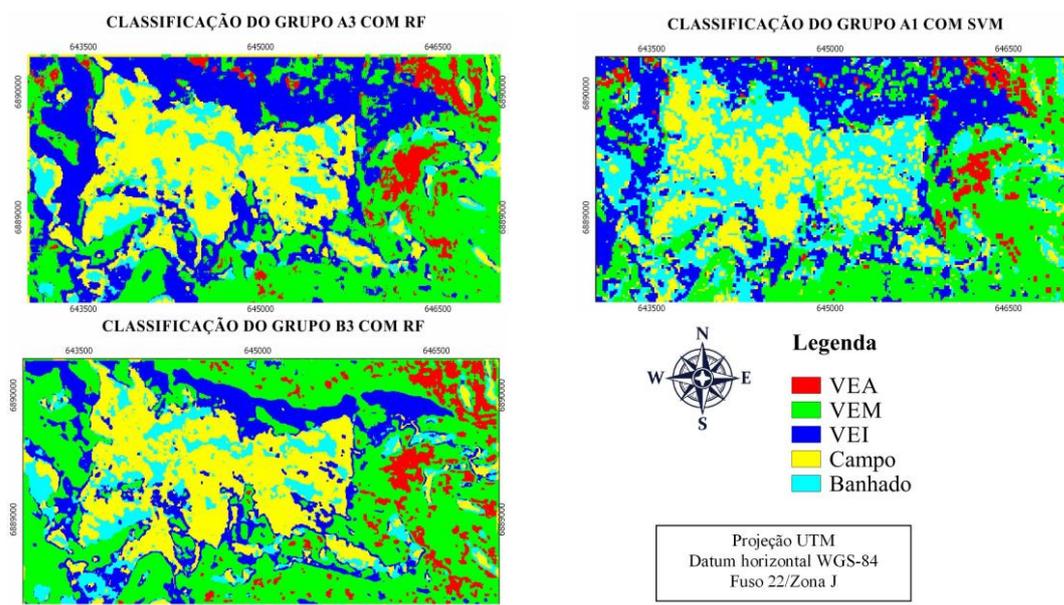


Figura 1. Melhores resultados da classificação com os algoritmos RF e SVM nas imagens Landsat-8 e RapidEye, VEA: vegetação em estágio avançado; VEM: vegetação em estágio médio; VEI: vegetação em estágio inicial.

O teste z mostrou que o grupo de variáveis A3 associado ao classificador RF foi significativamente superior a todos os demais (Figura 1). Para o classificador SVM, a classificação com o grupo A1 foi significativamente superior aos demais grupos com o mesmo algoritmo. Nas imagens RapidEye, o grupo de variáveis B3 foi o que teve melhores resultados

com os dois classificadores não-paramétricos, RF e SVM (Figura 1). No caso do classificador MAXVER, os melhores resultados foram nos experimentos A1, B2 e B3, os quais não diferiram significativamente entre si. O grupo de informações B1 teve os piores resultados para os três algoritmos testados.

Percebeu-se que o aumento de variáveis melhorou a acurácia da classificação de imagens RapidEye, porém, piorou para as imagens Landsat-8 com os algoritmos SVM e MAXVER. Ao se utilizar o classificador RF, o aumento de variáveis aumentou a acurácia da classificação tanto das imagens Landsat-8 como RapidEye. Walton (2008) destaca a capacidade de o algoritmo RF lidar com variáveis explicativas fracas, o que explica ser este o único classificador que obteve aumento de acurácia com o acréscimo de variáveis em todas as situações testadas. Novack et al. (2011), ao avaliarem o desempenho de diferentes grupos de variáveis de imagens Quickbird e Worldview-2 nos classificadores RF, árvore de decisão, árvore de regressão e SVM, concluíram que o RF alcançou maior acurácia dentre todos. No estudo desses autores, o classificador SVM obteve o pior desempenho, o que eles atribuíram à alta dimensionalidade e correlação do espaço de atributos. Pelo fato de outros classificadores avaliarem cada atributo internamente, eles são menos influenciados pela correlação e dimensionalidade do espaço de atributos. Além disso, o aumento de variáveis, no caso dos grupos A2 e A3, pode ter ocasionado o superajustamento dos dados às amostras de treinamento no modelo SVM e MAXVER (Novack et al., 2011).

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. No geral, para ambas as imagens, destacaram-se as médias texturais das bandas obtidas a partir da matriz de co-ocorrência. A média textural da banda azul foi considerada a variável mais importante para as imagens dos dois sensores. A banda azul pode ter sido utilizada para discriminar as classes de vegetação das classes campo e banhado. Estas duas classes, por possuírem maior presença de solo, têm resposta espectral comparativamente superior à vegetação nesta faixa do espectro (Francisco e Almeida, 2012). Quanto às demais medidas texturais, destacaram-se ainda as métricas contraste e dissimilaridade, principalmente de bandas relacionadas ao infravermelho. Li et al. (2014) realizaram a classificação do uso da terra com imagens Landsat TM com e sem as duas bandas no infravermelho, e tiveram um acréscimo de 3 a 5% de acurácia com o uso destas bandas. Quanto ao contraste, valores elevados indicam textura mais rugosa (Francisco e Almeida, 2012), característica importante para discriminar tipologias florestais.

A aplicação da informação textural foi apontada em vários estudos para melhor discriminação de classes de vegetação (Sette e Maillard, 2011; Gomes e Maillard, 2015). Sette e Maillard (2011), ao classificarem os estádios sucessionais da vegetação de Floresta Ombrófila Densa em imagens do satélite FORMOSAT-2, no sul da Bahia, obtiveram acurácia de 60,5% ao utilizar somente as bandas do visível e 91% ao incluir atributos texturais. Na imagem Landsat-8, as bandas puras azul e infravermelho próximo ficaram entre as dez variáveis mais importantes. Na RapidEye, as bandas texturais obtiveram maior importância que as bandas espectrais puras. Isto explica o fato de o experimento B1 ter obtido menor índice de acerto para os três classificadores testados.

O IVDN destacou-se como a quinta informação mais importante, após a média textural das duas bandas no infravermelho de ondas curtas para o experimento com imagens do sensor OLI. No caso da imagem RapidEye, a média textural da banda vermelho limítrofe ou *red-edge* foi a segunda no *ranking* de importância das variáveis. Alguns estudos mostraram que a incorporação da banda vermelho limítrofe das imagens RapidEye, por ser sensível ao teor de clorofila das plantas, aumentou a separabilidade das classes de uso da terra (Adelabu et al.,

2014; Adam et al., 2014) e, conseqüentemente, melhorou a acurácia da classificação das classes vegetação, agricultura e florestas nesses estudos.

Quanto ao desempenho dos algoritmos utilizados, outros estudos apontaram a superioridade de classificadores por aprendizagem de máquina em comparação a abordagens convencionais. Adam et al. (2014), ao compararem o desempenho dos algoritmos SVM e RF para a classificação de diferentes classes de cobertura da terra, obtiveram desempenhos similares nestes dois algoritmos, porém a maior acurácia foi alcançada pelo RF. Lu et al. (2014) compararam o desempenho dos algoritmos MAXVER, redes neurais artificiais, árvores de decisão, SVM e OBIA em imagens Landsat-5/TM e ALOS/PALSAR para classificar o estágio sucessional da vegetação no Bioma Amazônia. Os autores concluíram que imagens do satélite Landsat foram mais eficientes para esse propósito que imagens ALOS/PALSAR. Quanto aos algoritmos utilizados pelos autores, 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. Attarchi e Gloaguen (2014), ao testarem os algoritmos SVM, redes neurais, RF e MAXVER para discriminar os estágios de sucessão florestal em regiões montanhosas com imagens Landsat-7 ETM+ e SAR, concluíram que o SVM e o RF produziram melhores resultados em comparação aos demais algoritmos tradicionais, como o MAXVER.

4. Conclusão

As metodologias conduzidas com as imagens do satélite Landsat-8 quanto do RapidEye foram eficientes para discriminar os três estágios sucessionais da vegetação no PNSJ. Entretanto, os classificadores tiveram desempenho diferenciado conforme o grupo de variáveis utilizado. O algoritmo RF teve melhor desempenho com uso de variáveis texturais e índices de vegetação (i.e., grupo A3; índice Kappa de 0,88), enquanto os algoritmos SVM e MAXVER só apresentaram melhora com o aumento de variáveis no caso das imagens RapidEye. As menores performances foram observadas para as bandas espectrais puras das imagens RapidEye (grupo B1), dada a menor resolução radiométrica desta imagem em relação à Landsat-8, e ainda, a influência de sombras e variações intraclasses nas imagens de maior resolução espacial.

Quanto aos estágios sucessionais da vegetação, as três classes alcançaram acurácia do usuário e do produtor superiores a 50% nos algoritmos RF e SVM. O RF teve melhor desempenho para discriminar as classes VEA e VEM, enquanto o MAXVER teve melhor desempenho na classificação da VEI. A medida de importância da variável fornecida pelo RF teve significativa contribuição para fornecer uma visão de cada variável utilizada na classificação das imagens Landsat-8 e RapidEye. Para ambas as imagens, destacaram-se as métricas texturais GLCM: média, dissimilaridade e contraste, e as bandas do infravermelho.

A classificação automatizada mostrou-se efetiva para auxiliar no estudo de áreas extensas. As metodologias testadas são aplicáveis em outras áreas do Bioma Mata Atlântica, além de ter contribuído para uma avaliação comparativa de ferramentas disponíveis gratuitamente. Recomenda-se ainda testar abordagens utilizando OBIA com o intuito de melhorar a acurácia da classificação de imagens RapidEye.

Agradecimentos

Os autores agradecem à pesquisadora Thábata Cristina Faxina e ao professor Dr. Pedro Volkmer de Castilho por fornecerem os dados de campo utilizados neste trabalho.

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.

- Adelabu S., Mutanga O., Adam E. Evaluating the impact of red-edge band from Rapideye image for classifying insect defoliation levels. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 95, p. 34-41, 2014.
- Amaral, M. V. F.; Souza, A. L. de; Soares, V. P.; Soares, C. P. B.; Leite, H. G.; Martins, S. V.; Filho, E. I. F.; Lana, J. M. Avaliação e comparação de métodos de classificação de imagens de satélites para o mapeamento de estádios de sucessão florestal. **Revista Árvore**, v. 33, p. 575-82, 2009.
- Attarchi, S.; Gloaguen, R. Classifying Complex Mountainous Forests with L-Band SAR and Landsat Data Integration: A Comparison among Different Machine Learning Methods in the Hyrcanian Forest, **Remote Sensing**, v. 6, p. 3624-3647, 2014.
- BRASIL. Lei n. 11.428, de 22 de dezembro de 2006. Dispõe sobre a utilização e proteção da vegetação nativa do Bioma Mata Atlântica, e dá outras providências. Publicada no **Diário Oficial da União** Seção 1 em 26 de dezembro de 2006.
- BRASIL. Conselho Nacional do Meio Ambiente. 1994. Resolução CONAMA nº 04/94, de 4 de maio de 1994. Publicada no **Diário Oficial da União** em 17 jun. 1994, n. 114.
- Breiman, L. "Random Forests." *Machine Learning*, 45 (1) (2001): 5–32.
- Congalton, R. G. and Green, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers, 1999.
- Cortes, C.; V. Vapnik. Support-Vector Networks. **Machine Learning**, v. 20, p. 273–297, 1995.
- Engemap Geoinformação. **Relatório de produção final**. Edital de concorrência pública n. 0010/2009. Florianópolis SC, 218 p., 2012.
- Faxina, T. C. **Dilemas da regularização fundiária amigável no Parque Nacional de São Joaquim: Um estudo de caso – a valorização de áreas silvestres**. 2014. Dissertação (Mestrado em Engenharia Florestal)- Universidade do Estado de Santa Catarina, Lages, 2014.
- Francisco, C. N.; Almeida, C. M. Avaliação de Desempenho de Atributos Estatísticos e Texturais em uma Classificação de Cobertura da Terra Baseada em Objeto. **Bol. Ciênc. Geod.** v. 18, p. 302-326, 2012.
- Gomes, M. F.; Maillard, P. Using spectral and textural features from RapidEye images to estimate age and structural parameters of Cerrado vegetation. **International Journal of Remote Sensing**, v. 36, n 12, p. 3058-3076, 2015.
- Jensen, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres**. Tradução José Carlos Neves Epiphanyo (coord.)... [et al.]. São José dos Campos: Parêntese, 2011.
- Haralick, R. M.; Shanmugam, K.; Dinstein, I. H. Textural features for image classification. **IEEE Trans. Syst. Man Cybern.**, v. 3, p. 610–621, 1973.
- Huang, C.; Davis, L. S.; Townshend, J. R. G. An assessment of support vector machines for land cover classification. **Remote Sensing**, v. 23, p. 725–749, 2002.
- 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.
- Novack, T.; Esch, T.; Kux, H.; Stilla, U. Machine Learning Comparison between WorldView-2 and QuickBird-2-Simulated Imagery Regarding Object-Based Urban Land Cover Classification. **Remote Sens.**, v. 3, p. 2263-2282, 2011.
- Ribeiro, M. C.; Metzger, J. P.; Martensen, A.C.; Ponzoni, F. J.; Hirota, M. M. The Brazilian Atlantic Forest: How much is left, and how is the remaining forest distributed? Implications for conservation. **Biological Conservation**, v. 142, p. 1141-1153, 2009.
- Sette, P. G. C.; Maillard, P. Análise de textura de imagem de alta resolução para aprimorar a acurácia da classificação da mata atlântica no sul da Bahia. In: XV Simpósio Brasileiro de Sensoriamento Remoto – SBSR, Curitiba, Paraná, **Anais...** INPE: São José dos Campos, p. 2020, 2011.
- 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.
- Walton, J. T. Subpixel Urban Land Cover Estimation: Comparing Cubist, Random Forests And Support Vector Regression. **Photogrammetric Engineering & Remote Sensing**, v. 74, p. 1213-1222, 2008.