

Estimativa de biomassa em fitofisionomias do Cerrado usando dados do sensor Hyperion e regressão por mínimos quadrados parciais

Aline Daniele Jacon¹
Lênio Soares Galvão¹
João Roberto dos Santos¹
Edson Eyji Sano²

¹ Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
alinejacon@hotmail.com, {lenio.galvao, joao.roberto}@inpe.br

² Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis – IBAMA
SCEN Av. L4 Norte 70818-900 Brasília – DF, Brasil
edson.sano@ibama.gov.br

Abstract. Estimation of aboveground biomass (AGB) is challenging in large and complex areas such as the Brazilian Cerrado, which requires improved approaches to achieve the necessary accuracy. The development and launch of orbital hyperspectral sensors provide an opportunity to estimate the AGB using a number of metrics derived from these images. As a preparatory study for future hyperspectral missions, the AGB was estimated from the Hyperion images obtained by the Earth Observing-1 (EO-1) platform over the Ecological Station of Águas Emendadas, in central Brazil. We tested four groups of attributes with the partial least squares regression (PLSR): 146 spectral bands; 22 vegetation indices; 10,585 band ratios; and 24 absorption band parameters. We developed specific AGB/PLSR models for each group of attributes and tested a general model. The results showed a better performance with the use of all groups of spectral attributes in the general model ($R^2 = 0.66$, RMSE = 6.60 t.ha⁻¹) than with the use of each set of attributes. These values were comparable to those observed from the AGB-derived band ratio model ($R^2 = 0.65$, RMSE = 6.63 t.ha⁻¹). The Hyperion data allowed combination of different hyperspectral attributes in the AGB modeling. This may contribute for developing future works in the Cerrado ecosystem with the next generation of orbital hyperspectral sensors such as the Environmental Mapping and Analysis (EnMAP) and Hyperspectral Infrared Imager (HyspIRI), with much better signal-to-noise and larger swath width than the Hyperion.

Palavras-chave: above ground biomass, partial least squares regression, savannah, vegetation indices, biomassa acima do solo, regressão por mínimos quadrados parciais, savana, índices de vegetação.

1. Introdução

Como parte dos estudos preparatórios para futuras missões hiperespectrais, como o *Environmental Mapping and Analysis* (EnMAP) e o *Hyperspectral Infrared Imager* (HyspIRI), vários trabalhos têm lançado mão de dados hiperespectrais do sensor *Hyperion/Earth Observing One* (EO-1) para pesquisar diferentes ecossistemas. Por exemplo, pesquisadores de diversos países do denominado *EnMAP Scientific Advisory Group* (EnSAG) identificaram o Cerrado como um dos *hotspots* mundiais de maior biodiversidade e interesse da missão. Eles têm destacado a importância de mapear e monitorar suas fitofisionomias e de quantificar sua biomassa usando dados da futura missão EnMAP (LEITÃO et al., 2015). Apesar de bastante ruidoso, o Hyperion ainda é o instrumento que melhor representa o estado-da-arte do sensoriamento remoto hiperespectral orbital, possuindo, contudo, especificações técnicas inferiores às do futuro EnMap e HyspIRI.

Um dos parâmetros biofísicos da vegetação de maior interesse por parte da comunidade científica na última década é a biomassa acima do solo (AGB - *aboveground biomass*). Sua modelagem espacial é relevante para os estudos de emissão e reabsorção de carbono em escala global e, conseqüentemente, para a elaboração de inventários com dados mais confiáveis para discussão em programas internacionais destinados à redução de emissões de gases de efeito estufa (LEI et al., 2012; LAURIN et al., 2014). Segundo pesquisadores do

EnSAG, a estimativa da AGB é um desafio em áreas extensas e complexas, como é o caso do Cerrado, necessitando assim do constante desenvolvimento de metodologias que busquem ganhos de precisão em sua estimativa (GUANTER et al., 2015; LEITÃO et al., 2015). Uma das abordagens dominantes na estimativa de AGB a partir de dados hiperespectrais é a regressão por mínimos quadrados parciais (PLSR - *partial least squares regression*). PLSR consegue lidar com a forte colinearidade dos dados causada pelo grande número de bandas espectrais e atributos hiperespectrais gerados. Essa técnica tem apresentado resultados satisfatórios em estudos relacionados às estimativas de biomassa a partir de dados hiperespectrais (LAURIN et al., 2014; LEI et al., 2012; MARABEL; ALVAREZ-TABOADA, 2013).

O objetivo do trabalho é testar a utilização combinada de diferentes atributos hiperespectrais, gerados por meio de imagens do sensor Hyperion/EO-1, para compor um modelo de estimativa de biomassa para as fitofisionomias do Cerrado na Estação Ecológica de Águas Emendadas (ESEC-AE), utilizando o procedimento estatístico PLSR.

2. Metodologia de trabalho

2.1 Área de estudo

A ESEC-AE representa uma das áreas protegidas de maior biodiversidade dos Cerrados, perfazendo aproximadamente 10000 ha, distante 50 km a nordeste de Brasília. A altitude varia de 1000 a 1200 m e a precipitação média anual é de 1550 mm, concentrada de outubro a abril. A temperatura média anual é de 21°C (MAIA; BAPTISTA, 2008). As fitofisionomias que nela ocorrem, segundo o mapa de vegetação do plano de manejo (GEO LÓGICA/ECOTECH, 2009) e levantamento de campo, especificamente realizado para o presente trabalho, foram subdivididas em: campo limpo (CaL) e campo sujo (CaS) (compondo as formações campestres); campo cerrado (CaC), cerrado ralo (CR), cerrado típico (C) e cerrado denso (CD) (formações de estrutura savânica com progressivo adensamento de indivíduos arbóreo-arbustivos); e mata de galeria (formação florestal). Outras feições também presentes na área como veredas, regeneração e solo exposto, também foram observadas e incluídas na classe “Outros” (Figura 1). Decidiu-se não amostrar, com parcelas de inventário, a mata de galeria pela sua dimensão reduzida na área de estudo.

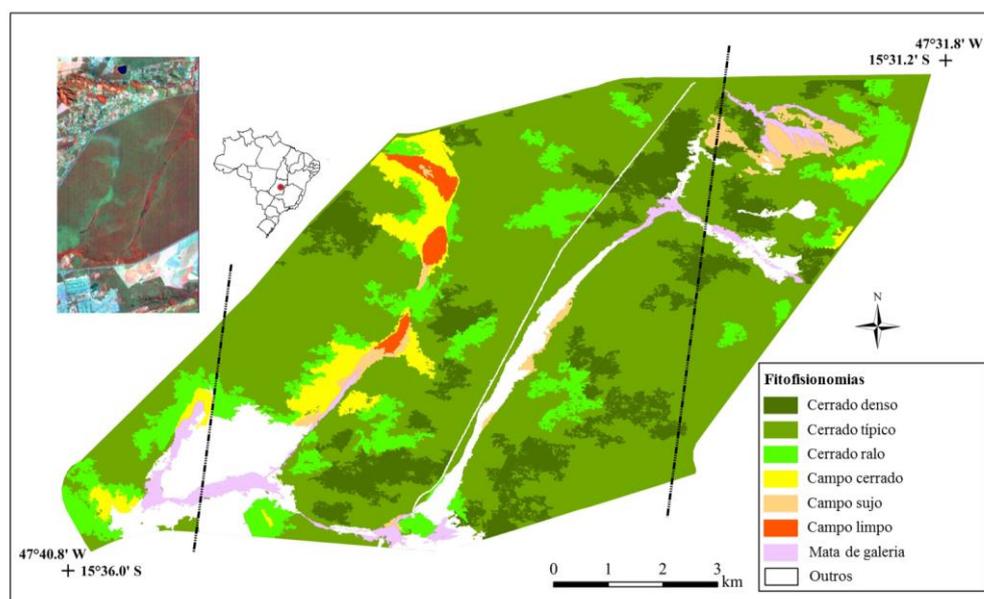


Figura 1. Localização da ESEC-AE e distribuição espacial das fisionomias que compõem sua paisagem. Linhas tracejadas indicam a área coberta pela imagem Hyperion em 2014, representada a esquerda. Fonte: Adaptado de Geo Lógica/Ecotech (2009).

2.2 Aquisição e tratamento dos dados de campo

A campanha de campo foi realizada em julho de 2015, mês correspondente ao período seco. Foram amostradas 45 parcelas de 20 m x 50 m, dimensão adotada por Felfili et al. (2005), totalizando 4,5 ha. Para as parcelas de CD, C, CR e CaC, foram medidos todos os indivíduos arbóreo-arbustivo vivos com diâmetro com casca (tomado a 30 cm da base do solo - Db) igual ou superior a 5 cm. Todos os indivíduos incluídos na medição foram identificados botanicamente (família e espécie) por um para-botânico, especialista da Embrapa Cerrados. A altura total (Ht) dos indivíduos inventariados foi medida com auxílio de uma régua com altura conhecida.

Nas fitofisionomias CaS e CaL foram alocadas 5 subparcelas de 1 m² distribuídas sistematicamente de 10 em 10 m dentro da parcela de 20 x 50 m, conforme recomendado por Felfili et al. (2005), onde todo material herbáceo foi coletado, ensacado e pesado ainda em campo com uma balança de pequeno porte. Depois, no laboratório da Embrapa Cerrados, as amostras de cada subparcela foram preparadas, pesadas e posteriormente levadas para secagem em estufa de circulação forçada de ar, a uma temperatura de aproximadamente 65 °C durante 48 horas, ou até a estabilização do seu peso de matéria seca, procedimento esse recomendado por Ribeiro et al. (2011).

Nas parcelas de CD, C, CR e CaC, a estimativa de biomassa seca acima do solo de cada indivíduo lenhoso vivo foi obtida por meio da equação alométrica proposta por Rezende et al. (2006) para o cerrado *sensu stricto* em Brasília - DF. A AGB foi considerada como a soma das biomassas individuais, extrapoladas para tonelada por hectare. Nas parcelas de CaS e CaL, os cálculos de biomassa foram efetuados seguindo o método da proporcionalidade proposto por Ribeiro et al. (2011).

2.3 Pré-processamento da imagem Hyperion

A imagem utilizada para modelagem da biomassa foi de julho de 2014, obtida a partir da plataforma *Earth Explorer* da USGS/NASA. Não foi possível utilizar uma imagem concomitante ao campo, pois, neste período, não houve aquisição de imagens Hyperion. Uma análise das condições pluviométricas no decorrer dos anos 2014 (período de imageamento) e de 2015 (aquisição de dados de campo) foi verificada quanto ao estado de similaridade das condições sazonais da vegetação.

Os pré-processamentos e os processamentos realizados na imagem foram feitos no aplicativo ENVI 5.0. A imagem Hyperion/EO-1 apresenta pixels ruidosos que formam linhas ou “faixas escuras”, perpendiculares à linha de varredura, conhecidas como *stripes*, que compreendem as informações perdidas durante a aquisição dos dados. Os *stripes* foram substituídos automaticamente pela média de seus vizinhos na direção horizontal por meio de um algoritmo. Os dados de radiância foram convertidos para reflectância de superfície utilizando o *Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes* (FLAASH), o qual é baseado no modelo de transferência radiativa *Moderate Resolution Transmittance Code* (MODTRAN-4). O modelo atmosférico utilizado foi o tropical / rural, com visibilidade de 70 km. A banda de absorção de vapor d'água utilizada para a estimativa desse constituinte atmosférico foi a de 1135 nm. Um algoritmo para a remoção de ruído e feições espúrias decorrentes da correção atmosférica foi aplicado sobre os dados. Bandas posicionadas em torno de 1400 e 1900 nm foram excluídas da análise subsequente de dados devido à forte absorção atmosférica pelo vapor de água, que limita o uso destes dados mesmo após a correção atmosférica (GALVÃO et al., 2005). No total, 146 bandas espectrais foram utilizadas nas análises subsequentes.

A correção geométrica da imagem Hyperion LIR foi realizada utilizando-se pontos de controle sobre feições correspondentes entre a imagem Hyperion e uma imagem TM/Landsat 5 ortorretificada. Para a transformação foi usado um polinômio do primeiro grau, adotando-se

o sistema de projeção UTM zona 23S, datum WGS-84. Após o georreferenciamento, foi avaliado o resíduo em unidades de pixel, seguido pela reamostragem dos pixels da cena Hyperion pelo método de vizinho mais próximo.

2.4 Geração de atributos hiperespectrais

Atributos hiperespectrais visam caracterizar e representar a estrutura e fisiologia da vegetação, assim como a bioquímica e estrutura do dossel (GALVÃO et al., 2013). Para caracterizar espectralmente as fitofisionomias do cerrado, os seguintes atributos foram considerados: 1) reflectância de bandas; 2) índices de vegetação (IVs); 3) razões de bandas; 4) parâmetros de bandas de absorção.

Para caracterizar a reflectância foram utilizadas as 146 bandas resultantes do pré-processamento aplicado na imagem Hyperion.

Foram calculados 22 índices de vegetação de bandas estreitas descritos por Roberts et al., (2011). Os IVs mais relacionados com a estrutura do dossel são: *Enhanced Vegetation Index* (EVI); *Normalized Difference Vegetation Index* (NDVI); *Visible Atmospherically Resistant Index* (VARI) e o *Visible Green Index* (VIg). Os IVs mais associados com a bioquímica são: *Anthocyanin Reflectance Index* (ARI); *Cellulose Absorption Index* (CAI); *Carotenoid Reflectance Index 1* (CRI1); *Leaf Water Vegetation Index 2* (LWVI2); *Modified Chlorophyll Absorption Ratio Index* (MCARI); *Moisture Stress Index* (MSI); *Normalized Difference Infrared Index* (NDII); *Normalized Difference Lignin Index* (NDLI); *Normalized Difference Water Index* (NDWI); *Plant Senescence Reflectance Index* (PSRI); *Pigment Specific Simple Ratio* (PSSR); *Structure Insensitive Pigment Index* (SIPI) e *Water Band Index* (WBI). Finalmente, aqueles que melhor expressam a fisiologia da vegetação são: *Photochemical Reflectance Index* (PRI); *Red Edge Normalized Difference Vegetation Index* (RENDVI); *Red Edge Position Index* (REPI); *Red-Edge Vegetation Stress Index* (RVSI) e *Vogelmann Red Edge Index* (VOG).

Para o cálculo das razões de bandas foram determinadas todas as possíveis combinações empíricas de bandas simples (numerador/denominador) derivadas das 146 bandas do sensor Hyperion, resultando em 10585 razões.

Os parâmetros de banda de absorção foram calculados pelo processo de remoção do contínuo espectral (CLARK; ROUSH, 1984). A remoção do contínuo serviu como base para calcular os parâmetros que descrevem as características das bandas de absorção, sendo que, variações desses parâmetros descrevem, em termos simples, a variação nas propriedades de absorção (KOKALY, 2011). Os parâmetros calculados foram: profundidade, largura, área e assimetria para as bandas de absorção posicionadas em 680 nm (clorofila); 980 nm e 1200 nm (água nas folhas); 1700 nm, 2100 nm e 2300 nm (lignina-celulose) (GALVÃO et al., 2005).

2.5 Análises estatísticas

Os atributos hiperespectrais utilizados nessa etapa foram extraídos de 45 pixels, correspondentes às parcelas amostradas em campo, gerados para imagem de julho de 2014. As fitofisionomias analisadas foram CD, C, CR, CaC, CaS e CaL.

Inicialmente foi realizada uma análise exploratória dos dados a fim de se conhecer a relação entre cada conjunto de variáveis independentes e a dependente, assim como a relação dentro de cada conjunto de variáveis X.

Para avaliar a relação entre o conteúdo calculado de biomassa viva/seca acima do solo e os atributos hiperespectrais foi empregada a regressão PLSR pelo método NIPALS. Para isto, a análise do conteúdo de biomassa foi abordada de maneira geral, ou seja, o objetivo não foi o ajuste de um modelo para cada fitofisionomia, mas sim, a construção de um modelo que pudesse abranger toda a variabilidade de biomassa existente na área de estudo. Ao todo, foram ajustados cinco modelos, permanecendo única a variável dependente biomassa (Y) e

variando o conjunto de variáveis independentes X, com um total de 146 variáveis X no modelo reflectância, 22 no modelo IVs, 10585 no modelo razões de bandas, 24 no modelo parâmetros de banda de absorção e 10777 no modelo Geral (todos os atributos). As análises foram realizadas utilizando o *software* Unscrambler® X 10.2 (CAMO Software Inc., Woodbridge, Noruega).

A validação dos modelos foi realizada por meio da validação cruzada, método utilizado por diferentes autores para verificar o poder preditivo dos modelos PLSR (LAURIN et al., 2014; MARABEL; ALVAREZ-TABOADA, 2013). No geral, os resultados dos modelos neste estudo foram avaliados em termos do número de fatores (PCs), do coeficiente de determinação (R^2), e da raiz quadrada do erro quadrático médio (RMSE). Para considerar um modelo com maior acurácia do que outro, a redução do RMSE da validação cruzada deve ser em pelo menos 2% entre os modelos comparados. Esse mesmo critério foi utilizado para estabelecer o número ótimo de PCs em cada modelo, ou seja, o critério para adicionar um novo fator no modelo foi a redução do RMSE da validação cruzada em pelo menos 2% (KOOISTRA et al., 2004).

3. Resultados e Discussão

Na Tabela 1 estão listados os valores médios dos parâmetros amostrados e estimados nas fitofisionomias CD, C, CR e CaC. Para CaL e CaS, apenas a biomassa foi calculada, conforme metodologia descrita anteriormente.

Tabela 1. Valores médios e desvio padrão dos parâmetros biofísicos de cada fitofisionomia amostrada na ESEC-AE.

PARÂMETROS	FITOFISIONOMIAS					
	CD	C	CR	CaC	CaS	CaL
Número de parcelas	7	14	6	6	2	10
Biomassa (t.ha ⁻¹)	34.46 ± 2.7	26.56 ± 6.93	14.08 ± 5.93	9.73 ± 3.38	5.83 ± 1.35	3.98 ± 0.70
Altura média (m)	3.00 ± 1.7	2.66 ± 1.6	2.51 ± 1.3	2.32 ± 1.3	-	-
Área basal (m ² .ha ⁻¹)	22.03 ± 1.54	16.52 ± 2.16	11.72 ± 4.68	8.27 ± 1.60	-	-
Densidade (ind.ha ⁻¹)	2415 ± 388	2171 ± 475	1635 ± 394	1162 ± 273	-	-

Na análise feita entre biomassa e o conjunto reflectância, a melhor correlação positiva foi obtida em 874 nm, região do infravermelho próximo (IVP), resultando em um coeficiente de correlação (r) de +0,66. Esse resultado indica que uma maior reflectância em 874 nm, ter-se-á um maior conteúdo de biomassa aérea dessas fitofisionomias, até atingir um patamar de saturação do sinal. A melhor correlação negativa foi obtida em 1719 nm, região do SWIR 2, com um r de -0,76. Portanto, quanto menor for a reflectância em 1719 nm, maior será a biomassa.

A relação entre a biomassa e os índices RVSI, REPI, PRI, NDLI, MSI, MCARI e CAI, não foram significativas ($p < 0,05$). As melhores correlações com a biomassa estão associadas aos índices de banda estreita PSSR ($r = +0,81$) e PSRI ($r = -0,77$), relacionados com a bioquímica; RENDVI ($r = +0,79$), relacionado com a fisiologia e o estresse; e EVI ($r = +0,78$) e NDVI ($r = +0,77$), relacionados a estrutura da vegetação.

As melhores correlações positivas entre as razões de banda e a biomassa foram as resultantes da relação IVP/visível, principalmente no comprimento de onda vermelho. Essa relação pode ser explicada pelo aumento da concentração de pigmentos fotossintetizantes e o aumento do índice de área foliar (IAF), maior complexidade do dossel, com o incremento de biomassa, resultando em maior absorção da radiação na região do visível e aumento da reflectância no IVP (ASNER, 2008). As melhores correlações negativas resultaram da relação vermelho/verde, SWIR 1/IVP e SWIR 2/IVP. A região do SWIR relaciona-se com o conteúdo

de água na vegetação, e em menor grau, com o conteúdo de nitrogênio, celulose e lignina (ASNER, 2008).

Correlações significativas com a biomassa foram obtidas apenas para os parâmetros das bandas posicionadas em 680 nm e 980 nm, associadas à absorção por clorofila e água nas folhas, respectivamente. Os parâmetros em 1200 nm, também associados à absorção por água, e os parâmetros em 1700, 2100 e 2300 nm, associados à absorção por lignina e celulose, não foram considerados significativos.

A comparação de desempenho dos modelos específicos e geral pode ser vista na Figura 2.

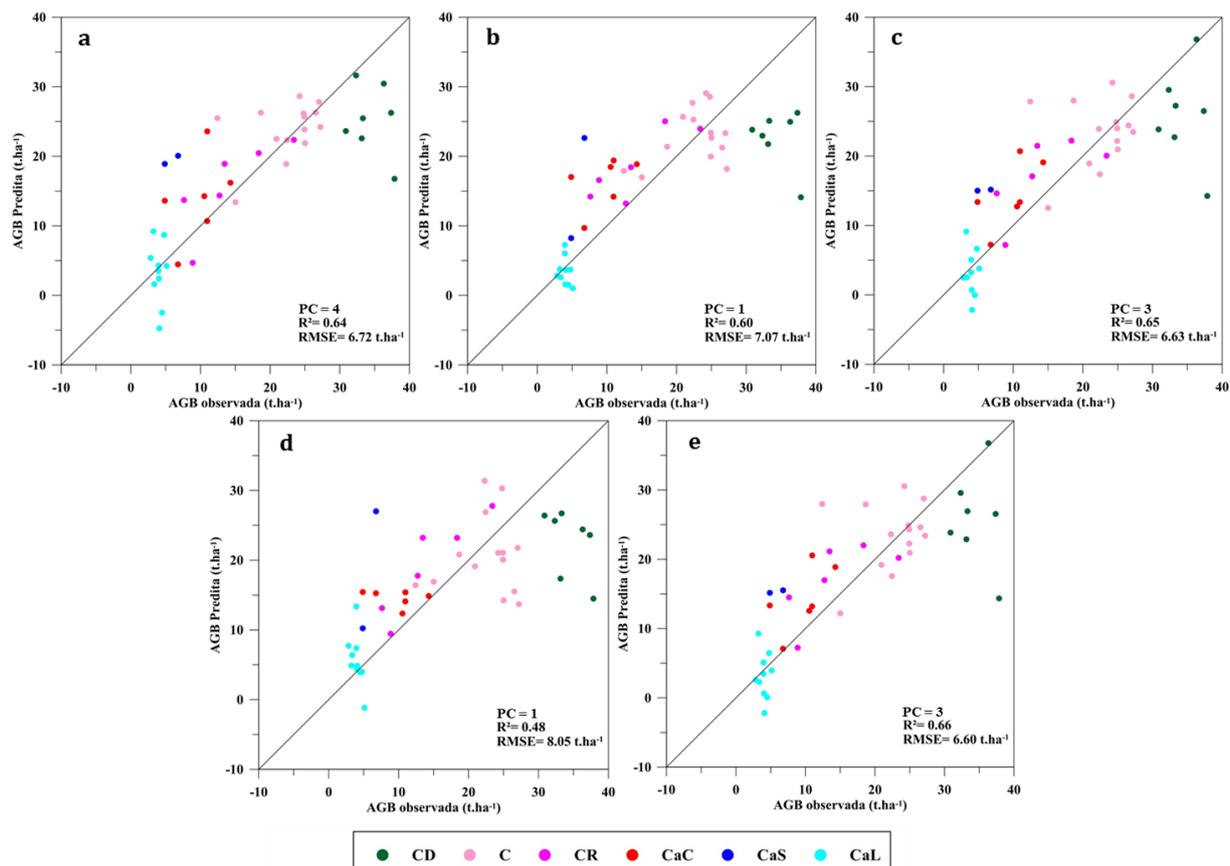


Figura 2. Valores de AGB observados em relação aos valores preditos na validação cruzada nos modelos PLSR; (a) modelo reflectância; (b) modelo IVs; (c) modelo razões de bandas; (d) modelo parâmetros de bandas de absorção; (e) modelo geral, com o conjunto total de atributos.

Tendo como base o modelo de reflectância, pois este não sofreu nenhum tipo de transformação, os modelos com IVs e parâmetros descritores das bandas de absorção atingiram resultados inferiores aos demais modelos. Mesmo necessitando de apenas um fator (PC) para a modelagem, as transformações do espectro para esses dois conjuntos de variáveis geraram um aumento do RMSE em 2,3% no modelo com IVs e de 8,2% no modelo com parâmetros de bandas de absorção. Esses resultados podem ser explicados pela baixa correlação entre a biomassa observada e algumas das variáveis analisadas dentro desses dois conjuntos de dados.

Ocorreu uma redução do RMSE e incremento no R² nos modelos com razões de bandas. Porém, em geral, com base no critério mencionado acima, a melhora não atingiu 2% de redução do RMSE. O grande número de variáveis independentes do modelo geral, oriundas do conjunto razões de bandas, resultou em valores muito similares de R² e RMSE. Em resumo, dentre os modelos PLSR específicos aqueles derivados de reflectância e de razões de

bandas mostraram os maiores valores de R^2 e os menores valores de RMSE, com o pior desempenho sendo observado para o modelo com parâmetros descritores das bandas de absorção. O modelo geral, com todos os atributos, mostrou um pequeno ganho na estimativa de AGB quando comparado com os modelos específicos de reflectância ou razões de banda.

Estudos em diferentes formações vegetais confirmam o potencial da regressão PLSR na estimativa de biomassa utilizando dados hiperespectrais (CHO et al., 2007; MAREBEL; ALVAREZ-TABOADA, 2013; VYAS; KRISHNAYYA, 2014). No presente estudo, o modelo reflectância demonstrou superioridade no ajuste por PLSR (RMSE = 6,72 t.ha⁻¹) em comparação ao ajuste por regressão linear simples com bandas individuais (RMSE = 7,24 t.ha⁻¹), resultando em redução do RMSE em 3,1 %. No entanto, para os modelos IVs, razões de bandas e parâmetros de bandas de absorção, o ajuste de parâmetros individuais apresentou melhores resultados com relação à modelagem PLSR, resultados contrários aos encontrados por Cho et al. (2007) e Marabel e Alvarez-Taboada (2013).

4. Considerações finais

O uso de dados do sensor hiperespectral Hyperion viabilizou a combinação de diferentes métricas na modelagem da AGB das fitofisionomias do Cerrado, possibilitando a compreensão da importância isolada e combinada dos diferentes atributos hiperespectrais como dados de entrada nos modelos PLSR. O comportamento anômalo de algumas parcelas, com relação à estimativa de AGB, foi investigado e constatou-se que, a presença de espécies invasoras, exposição do solo em maior ou menor grau, assim como indícios de queimada, podem ter influenciado em erros de estimativa. Esses aspectos foram registrados em algumas localidades da ESEC-AE, confirmando dificuldades de estimativas com melhor acurácia de parâmetros biofísicos em Cerrados, já relatadas por diferentes autores. Essa gama de atributos e possibilidades fornecidas a partir de dados hiperespectrais, podem embasar o desenvolvimento de estudos, principalmente no bioma Cerrado, com os futuros sensores hiperespectrais HypSIRI e EnMAP. Esses sensores irão operar em faixas de imageamento mais amplas e com melhor relação sinal ruído do que o Hyperion, possibilitando, por conseguinte, a obtenção de maior precisão nas análises.

Agradecimentos

Os autores agradecem ao Instituto Brasília Ambiental (IBRAM) pela autorização de pesquisa 06/2015 (projeto 391.000.740/2015); à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES); e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) (projetos 304291/2013-7 e 303228/2013-0). Agradecemos também ao apoio de campo fornecido pela Empresa Brasileira de Pesquisa Agropecuária (Embrapa - Cerrados), especialmente ao para-botânico Sr. José Ferreira Paixão.

Referências Bibliográficas

- Asner, G.P. Hyperspectral remote sensing of canopy chemistry, physiology, and biodiversity in tropical rain forests. In: Kalacska, M; Sanchez-Azofeifa G. A. (Eds). **Hyperspectral remote sensing of tropical and subtropical forests**. Taylor and Francis Group - CRC Press, 2008. Chapter 12, p. 261-296.
- Cho, M. A.; Skidmore, A.; Corsi, F.; Van Wieren, S. E.; Sobhan, I. Estimation of green grass/herb biomass from airborne hyperspectral imagery using spectral indices and partial least squares regression. **International Journal of Applied Earth Observation and Geoinformation**, v. 9, n. 4, p. 414-424, 2007.
- Clark, R. N.; Roush, T. L. Reflectance spectroscopy: quantitative analysis techniques for remote sensing applications. **Journal of Geophysical Research**, v. 89, n. 7, p. 6329-6340, 1984.

- Felfili, J. M.; Carvalho, F.A.; Haidar, R.F. **Manual para o monitoramento de parcelas permanentes nos biomas Cerrado e Pantanal**. Brasília: EdUnB, 2005. 55p.
- Galvão, L. S.; Formaggio, A. R.; Tisot, D. A. Discrimination of sugarcane varieties in southeastern Brazil with EO-1 Hyperion data. **Remote Sensing of Environment**, v. 94, n. 4, p. 523–534, 2005.
- Galvão, L.S.; Breunig, F. M.; Santos, J.R.; Moura, Y. M. View-illumination effects on hyperspectral vegetation indices in the Amazonian tropical forest. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 291-300, 2013.
- Geo lógica/Ecotech. **Plano de manejo**: programa de proteção, planejamento e gestão para a Estação Ecológica de Águas Emendadas (ESEC-AE). Brasília, 2009.
- Guanter, L. et al. Monitoring natural ecosystem and ecological gradients: perspectives with EnMAP. **Remote Sensing**, v. 7, n. 10, p. 13098–13119, 2015.
- Kokaly, R.F. **PRISM**: processing routines in IDL for spectroscopic measurements (installation manual and user's guide, version 1.0). U.S. Geological Survey Open-File Report 2011–1155, 432p. Disponível em <<http://pubs.usgs.gov/of/2011/1155/>>. Acesso em 20 set. 2015.
- Kooistra, L.; Salas, E. A.; Clevers, J. G. P.; Wehrens, R.; Leuven, R. S. E.; Nienhuis, P.; Buydens, L. M. . Exploring field vegetation reflectance as an indicator of soil contamination in river floodplains. **Environmental Pollution**, v. 127, n. 2, p. 281–290, 2004.
- Laurin, G. V.; Chen, Q.; Lindsell, J. A.; Coomes, D. A.; Frate, F. D.; Guerriero, L.; Pirotti, F.; Valentini, R. Above-ground biomass estimation in an African tropical forest with LIDAR and hyperspectral data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.89, p. 49–58, 2014.
- Lei, C. L.; Ju, C. Y.; Cai, T. J.; Jing, X.; Wei, X. H.; Di, X. Y. Estimating canopy closure density and above-ground tree biomass using partial least square methods in chinese boreal forests. **Journal of Forestry Research**, v. 23, p. 191–196, 2012.
- Leitão, P. J.; Schwieder, M.; Suess, S.; Okujeni, A.; Galvão, L. S.; Van Der Linden, S.; Hostert, P. Monitoring natural ecosystem and ecological gradients: perspectives with EnMAP. **Remote Sensing**, v. 7, n. 10, p. 13098–13119, 2015.
- Maia, J. M. F.; Baptista, G. M. M. Meio físico: clima. In: Fonseca, F. O. (Org.). **Águas Emendadas**. 1 ed. Brasília: SEDUMA, 2008. Cap. V-V.2, p. 101-109.
- Marabel, M.; Alvarez-Taboada, F. Spectroscopic determination of above ground biomass in grasslands using spectral transformations, support vector machine and partial least squares regression. **Sensors**, v. 13, n. 8, p. 10027–51, 2013.
- Rezende, A V; Vale, A T. DO; Sanquetta, C. R.; Figueiredo Filho, A; Felfili, J. M. Comparação de modelos matemáticos para estimativa do volume, biomassa e estoque de carbono da vegetação lenhosa de um cerrado sensu stricto em Brasília, DF. **Scientia Forestalis**, v. 71, p. 65–76, 2006.
- Ribeiro, S. C.; Fehrmann, L.; Soares, C. P. B.; Jacovine, L. A. G.; Kleinn, C.; DE Oliveira Gaspar, R. Above- and belowground biomass in a brazilian cerrado. **Forest Ecology and Management**, v. 262, n. 3, p. 491–499, 2011.
- Roberts, D. A.; Roth, K. L.; Perroy, R. L. Hyperspectral vegetation indices. In: Thenkabail, P.S., Lyon, J.G., Huete, A. (Eds.), **Hyperspectral Remote Sensing of Vegetation**. CRC Press, Taylor and Francis Group, Boca Raton, FL. 2011. Chapter 14, p. 309–327.
- Vyas, D.; Krishnayya, N. S. R. Estimating attributes of deciduous forest cover of a sanctuary in India utilizing Hyperion data and PLS analysis. **International Journal of Remote Sensing**, v. 35, n. 9, p. 3197–3218, 2014.