

Modelos de estimativa de biomassa aérea utilizando dados *RapidEye* para a Floresta Nacional do Tapajós-PA

André Quintão de Almeida¹
Fabio Guimarães Gonçalves²
Robert Neil Treuhaft³
João Roberto dos Santos⁴
Paulo Maurício Lima de Alencastro Graça⁵
Rafael Rossi Viégas⁶

¹ Universidade Federal de Sergipe - UFS
Caixa Postal 353 - 49170-000 – São Cristóvão - SE, Brasil
andre.almeida@ufs.com.br

² Canopy Remote Sensing Solutions
Florianópolis - SC, Brasil
fabio@canopyrss.tech

³ Jet Propulsion Laboratory – JPL
California Institute of Technology - Pasadena, California - USA
robert.n.treuhaft@jpl.nasa.gov

⁴ Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
jroberto@dsr.inpe.br

⁵ Instituto Nacional de Pesquisas da Amazônia - INPA
69083-000 – Manaus - AM, Brasil
pmlag@inpa.gov.br

⁶ Universidade Federal de Santa Catarina - UFSC
Florianópolis - SC, Brasil
rafarviegas@gmail.com

Abstract. The objective of this study was to develop statistical models for estimating aboveground biomass (AGB) at Tapajós National Forest, Pará, Brazil, using spectral metrics derived from *RapidEye*. Measurements of diameter at breast height (DBH) and tree height were collected for 88 forest inventory plots (50 m x 50 m). All trees were identified to the genus and/or species level and their biomasses were estimated using allometric equations. The explanatory variables were extracted from the five spectral bands of the *RapidEye* satellite (5 m spatial resolution) and included individual bands, band ratios, and vegetation indices. Biomass estimation models were fitted using multiple linear regression and the non-parametric algorithm *Random Forest*. The predictive performance of the models was assessed based on the coefficient of determination (r^2) and the root mean square error (RMSE) calculated using a cross-validation procedure. The best regression model selected included three variables and presented a cross-validation r^2 of 0.67 and a RMSE of 95,4 Mg ha⁻¹ (50%). The *Random Forest* algorithm presented a better performance, with an r^2 of 0.75 and a RMSE of 84,1 Mg ha⁻¹ (45%). We conclude that metrics derived from the *RapidEye* sensor have the potential to explain a large portion of the variability in biomass at Tapajós, when combined with a more powerful statistical framework such as *Random Forest*.

Palavras-chave: Amazônia, REDD+, carbono florestal, análise de regressão, forest carbon, regression analysis, *Random Forest*.

1. Introdução

As Florestas Tropicais, em especial a amazônica, apresentam inúmeros benefícios para sociedade. Extremamente rica em biodiversidade e reguladora do ciclo da água na bacia hidrográfica amazônica, é fonte renovável de madeira, fibra, celulose, sementes, látex, além de outros serviços. As florestas tropicais armazenam aproximadamente 50% da biomassa terrestre do planeta e contribuem com cerca de 20% das emissões antrópicas de CO₂ em âmbito global, como resultado de desmatamento e degradação florestal (Houghton et al., 2009; Pan et al., 2011).

O Brasil figura entre os cinco maiores emissores do mundo de Gases de Efeito Estufa (GEE), com ~60% das suas emissões provenientes do setor de mudança de uso da terra (MUT), principalmente por desmatamentos conduzidos na região amazônica (Observatório do Clima, 2015). Desse modo, as florestas nacionais ganharam importância nos esforços de mitigação climática desenhados no âmbito da Convenção-Quadro das Nações Unidas sobre Mudança do Clima (UNFCCC), visando a redução de emissões de desmatamento e degradação florestal (REDD+).

A REDD foi uma medida adotada na Conferência das Partes sobre o Clima (COP-13), em Bali, em Dezembro de 2007. É um instrumento que inclui a possibilidade de financiar ações em ecossistemas florestais que visam atenuar os efeitos das Mudanças Climáticas Globais. Na COP-15, realizada em Copenhague, foram identificadas quatro principais ferramentas relacionadas à REDD: estimativa da biomassa e do carbono das florestas; gestão de grandes quantidades de dados espaciais; monitoramento do desmatamento e da degradação florestal; e modelagem do desmatamento futuro (Hajek et al., 2011). Essas ferramentas estão direta ou indiretamente relacionadas a técnicas de sensoriamento remoto, fundamentais para o monitoramento dos remanescentes florestais naturais pelo mundo.

Em 2009, o governo federal reconheceu formalmente a ameaça imposta pelas mudanças climáticas e a importância dos biomas brasileiros nesse contexto, adotando pela primeira vez compromissos voluntários para a redução de emissões de GEE (Lei nº 12.187, de 29 de dezembro de 2009). Dessa forma, a produção de inventários de emissões e remoções de GEE passou a ser fundamental tanto para cumprir as obrigações do país junto à UNFCCC, quanto para avaliar o status e a progressão das emissões ao longo do tempo, a fim de subsidiar políticas públicas que objetivem sua redução.

Estudos realizados em florestas tropicais úmidas mostram o potencial do sensoriamento remoto orbital em estimar características da vegetação, como altura, área basal e biomassa, além de outras variáveis de interesse (Powell et al., 2010; Du et al., 2010; Baccini et al., 2012; Harris et al., 2012). Na grande maioria destes estudos, imagens com média resolução espacial são utilizadas, como as da série do satélite *Landsat* (30 m de resolução espacial). No entanto, ainda são poucas as evidências do poder das imagens *RapidEye* em estudos de estimativa de biomassa florestal, contudo, espera-se que um menor tamanho de pixel (5 m) possa proporcionar um melhor resultado quando comparado com imagens de outros sensores. Estudos conduzidos em diferentes formações florestais (Rana et al., 2014) apontam erro (RMSE) de estimativa na ordem de 22 a 44 Mg ha⁻¹ (20 a 44%) com imagens *RapidEye*. Estudos mostram também que estas imagens podem detectar com mais precisão a perda de biomassa florestal provocada por exploração madeireira, o que sensores com resolução mais grosseira não são capazes de realizar de maneira tão fácil. Outro fato importante, observado por Argoty et al. (2012) em florestas tropicais da Nicarágua, é o poder de predição de biomassa vegetal por parte da banda espectral *Red-Edge*.

Portanto, o objetivo deste trabalho foi ajustar modelos para estimar biomassa aérea (AGB) na Floresta Nacional do Tapajós, PA, empregando-se dados do satélite *RapidEye*, associados às técnicas estatísticas de análise de regressão e da modelagem *Random Forest*.

2. Metodologia de Trabalho

2.1 Área de Estudo

O trabalho foi desenvolvido na Floresta Nacional do Tapajós-PA, localizada na porção oeste do Estado do Pará, Brasil (Figura 1). A FLONA possui uma área aproximada de 545.000 ha e está localizada entre as coordenadas 2°35' a 4°20'S e 24°40' a 55°40'O. O clima da região é do tipo Ami, de acordo com a classificação de Köppen, com temperatura média do ar anual próxima de 25° C e aproximadamente 1800 mm anuais de precipitação pluvial, concentradas entre os meses de janeiro e maio (IBAMA, 2004). Os solos predominantes são o Latossolo Amarelo e o Argissolo vermelho-amarelo. A vegetação predominante é classificada como do tipo Floresta Ombrófila Densa e Ombrófila Aberta (Veloso et al., 1991).

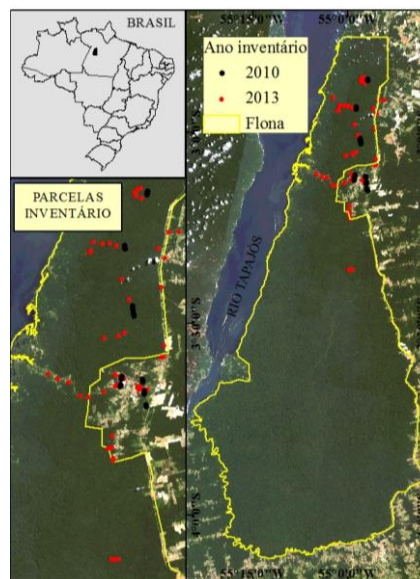


Figura 1. Localização da área de estudo e das parcelas de inventário florestal.

2.1 Dados de campo

Os dados de campo foram coletados em duas campanhas distintas, uma no ano de 2010, em 30 parcelas de inventário florestal, e outra em 2013, em 58 parcelas (total = 88). Em ambas as campanhas, as parcelas possuíam uma área de 0,25 ha (50 m x 50 m). Todos os indivíduos com diâmetro a altura do peito (DAP, em cm) ≥ 5 cm foram medidos nas parcelas em estágio sucessional inicial e todos aqueles com DAP ≥ 10 cm nas parcelas em estágios sucessionais mais avançados. Em 2010, foi estimado o DAP de todas as árvores vivas presentes na parcela com o auxílio de uma trena graduada. As respectivas alturas totais (em metros) foram estimadas de forma visual, por um único componente experiente da equipe e devidamente treinado. Nesta campanha, o centro de cada parcela foi identificado com um GPS Geodésico. Em 2013, também foram estimados os valores de DAP e altura total de cada árvore, porém, os valores de altura foram estimados com o auxílio de um clinômetro. No ano de 2013, o centro de cada parcela foi identificado com um GPS Geodésico. Todas as árvores foram identificadas ao nível de espécie ou gênero e seus respectivos valores de densidade da madeira (ρ) associados aos encontrados na literatura (Reyes et al., 1992; Chave et al., 2006).

Para se obter um modelo que represente toda a variação (*range*) na biomassa da FLONA, algumas parcelas de inventário foram localizadas no entorno da FLONA, em áreas de baixa biomassa, exploradas/desmatadas no passado (Figura 1). Isso possibilitou obter uma grande variação nos valores de biomassa e, conseqüentemente, ajustar modelos representativos da variação existente na vegetação local.

2.2 Estimativa de Biomassa

A biomassa área de cada indivíduo devidamente identificado na parcela foi estimada por equações alométricas (Chave et al., 2005; Chave et al., 2014) pré-estabelecidas para florestas tropicais e os valores estimados de DAP, altura total e densidade da madeira (ρ) das respectivas árvores. A escolha pela utilização dos modelos desenvolvidos por Chave está fundamentada no amplo número (1350) de árvores abatidas no momento do ajuste da equação, cobrindo assim, diferentes classes de diâmetro (5 a 156 cm), além de utilizar a informação da densidade da madeira, melhorando consideravelmente as estimativas. Cabe destacar também, que 43% das árvores utilizadas no ajuste da equação foram coletadas/abatidas na Amazônia brasileira. Para as espécies do gênero *Cecropia spp.* e as palmeiras, que possuem forma e valores de densidade significativamente diferentes das espécies da Floresta Amazônica, equações alométricas específicas foram utilizadas (Chave et al., 2005; Nelson et al., 1999).

A Biomassa Aérea (AGB, $Mg\ ha^{-1}$) acima do solo por parcela foi estimada pelo somatório de biomassa de todas as árvores vivas da parcela dividido pelo valor da área da parcela (0,25 ha). Para as parcelas onde os indivíduos foram medidos a partir do DAP de 10 cm, uma correção foi aplicada (Keller et al., 2001; Van Laar e Akça, 2007), com o intuito de estimar a biomassa dos indivíduos presentes na classe de diâmetro entre 5 e 10 cm. Como os dados de campo foram coletados em campanhas diferentes (2010 e 2013) e as imagens de satélite utilizadas são do ano de 2011, foi aplicado um modelo de crescimento específico do local (Neeff e Santos, 2005) para corrigir a defasagem (\pm) de biomassa entre os anos medidos e a data de coleta da imagem.

2.3 Dados *RapidEye*

As variáveis explicativas foram extraídas das bandas (g) espectrais de quatro diferentes cenas da constelação de satélites *RapidEye*. Duas registradas nos dias 17 de junho (ponto 375;376 e órbita 23;24), uma no dia 30 de julho (ponto 377 e órbita 24) e outra no dia 14 de agosto do ano de 2011 (ponto 376 e órbita 23). O nível de processamento do produto utilizado é do tipo 3A, com resolução espacial de 5 m, 16 bits, ortorretificado e com correção atmosférica. Todas as imagens estão projetadas sobre o sistema de coordenadas UTM, zona 21 S, Datum WGS 84.

Foram utilizadas cinco bandas espectrais: b1 - 0,4 a 0,51 μm (azul); b2 - 0,52 a 0,59 μm (verde); b3 - 0,63 a 0,685 μm (vermelha); b4 - 0,69 a 0,73 μm (*Red-Edge*); e, b5 - 0,76 a 0,85 μm (infravermelho próximo). Maiores informações sobre a banda *Red-Edge* consultar Bindel et al. (2011). A partir destas bandas, foram estimados quatro índices de vegetação (IVs) e as razões entre bandas (Tabela 1). Cabe ressaltar que cada índice foi estimado de forma duplicada, considerando as duas bandas espectrais na faixa do vermelho (banda do vermelho – b3 e a banda *Red-Edge* – b4), além da banda do infravermelho próximo (b5). Ao todo, foram utilizadas 33 variáveis explicativas, sendo 5 bandas espectrais (b1 a b5), 8 índices de vegetação e 20 razões entre bandas.

Tabela 1. Razão entre bandas e índices de vegetação extraídos da imagem *RapidEye*.

Parâmetros	Equação
Razão entre bandas	$b_{div}(l, p) = b_1(l, p) / b_2(l, p)$
Índices de vegetação (IVs)	
NDVI	$NIR - R / NIR + R$
SAVI	$(1 + 0,5) * (NIR - R) / NIR + R + 0,5$
MSAV	$[2NIR + 1 - RAIZ(2NIR + 1)^2 - 8(NIR - R)] / 2$
TVI	$RAIZ (NDVI + 0,5)$

em que: b = banda; l, p = pixel de posição correspondente; NIR = reflectância na banda do infravermelho; R = reflectância na banda do vermelho e do *Red-Edge*; $RAIZ$ = raiz quadrada.

2.4 Ajuste dos modelos

De posse dos valores de AGB de cada uma das 88 parcelas de inventário, modelos de predição de biomassa foram ajustados a partir de análise de regressão linear múltipla e a técnica não paramétrica de *Random Forest* (Breiman, 2001) entre a biomassa florestal medida *in situ* e as métricas espectrais derivadas da imagem *RapidEye*. O número de árvores (*n_{tree}*), o número mínimo de dados em cada nó terminal (*nodesize*) e o número de variáveis utilizadas em cada árvore (*mtry*) foi de, 500, 5 e 29, respectivamente. A seleção de modelos de regressão linear múltipla foi realizada a partir do ajuste de todos os possíveis modelos e escolha daqueles que apresentaram o menor critério bayesiano de informação (BIC) e o maior coeficiente de determinação (r^2). Os modelos selecionados foram avaliados com uso do teste t de Student a 1% de probabilidade. Em adição será conduzida análise de resíduos para avaliar a existência de tendência no erro, assim como da correlação entre variáveis explicativas (multicolinearidade).

O poder de predição dos modelos ajustados será avaliado a partir da técnica de validação cruzada, com base no coeficiente de determinação e na raiz do erro quadrático médio. Do conjunto de todas as observações (total = 88), 20% foram utilizadas para uma validação independente dos modelos selecionados. O processamento dos dados, toda análise gráfica e estatística foi realizada no software R 3.1.0 (R Development Core Team, 2014) e no pacote *randomForest*.

3. Resultados e Discussão

Os valores máximo e mínimo encontrados de Biomassa Aérea (AGB) na FLONA do Tapajós e áreas adjacentes foi de 0,152 e 731 Mg ha⁻¹, respectivamente, mostrando a grande variação de biomassa existente na região. O valor médio de AGB encontrado foi de aproximadamente 191 Mg ha⁻¹, valor semelhante ao encontrado em outros estudos realizados em regiões de Floresta Tropical (Argoty et al., 2012).

O melhor modelo de regressão ajustado, com três variáveis explicativas, teve como coeficiente de determinação o valor de 0,66 ($p < 0,0001$), um valor e BIC igual a -76 e uma equação igual a: $AGB (Mg\ ha^{-1}) = -4187,1 - 1790,6 (SAVIb4) + 3848,7 (b1\ b4^{-1}) + 1999,5 (b5\ b1^{-1})$. Pela análise da ANOVA, percebeu-se que todos os coeficientes estimados foram significativos ao teste t ao nível de 1%. Apesar de uma distribuição não muito normal dos resíduos, a validação cruzada do modelo apresentou um bom desempenho (Figura 2A), com valores de $r^2 = 0,67$ ($p < 0,0001$) e RMSE igual a 95,4 Mg ha⁻¹ (50%). Resultado semelhante ao encontrado ($58,8\ Mg\ ha^{-1} < RMSE < 91,4\ Mg\ ha^{-1}$) por Benítez et al. (2016) no trabalho de estimativa de AGB com dados *RapidEye* e técnicas de geoestatística na Floresta Amazônica Equatorial. É importante destacar que a banda espectral da faixa do comprimento de onda do vermelho *Red-Edge* (*b4*) presente na constelação de satélites *RapidEye* foi sensível as variações de biomassa da vegetação, estando presente no melhor modelo de regressão linear múltipla ajustado, na forma de razão de bandas ($b1\ b4^{-1}$). O mesmo comportamento também foi encontrado por Argoty et al. (2012) no estudo de estimativa de biomassa a partir de dados *RapidEye* no Norte da Nicarágua. Percebe-se que o SAVIb4 estimado com esta banda também entrou como variável explicativa do modelo. A mesma sensibilidade da banda *Red-Edge* foi encontrado por Aricak et al., (2015) em um estudo de estimativa de biomassa em florestas de *Pinus* localizada na província de Kars, Turquia. Analisando a Figura 2A, nota-se uma possível saturação dos dados *RapidEye* a partir de valores de biomassa acima de 500 Mg ha⁻¹ com o modelo de estimativa com base na regressão linear múltipla.

O modelo ajustado com o *Random Forest* apresentou um melhor desempenho (Figura 2B), com valores de $r^2 = 0,73$ e RMSE = 44% no momento do ajuste. Resultado superior aos encontrados por Benítez et al. (2016). Observa-se, entre os valores observados e estimados pelos modelos, uma menor dispersão no modelo *Random Forest*, principalmente para os

valores $> 500 \text{ Mg ha}^{-1}$ (Figura 2). Na validação cruzada, os resultados permaneceram praticamente os mesmos do ajuste, com valores de $r^2 = 0,75$ e $\text{RMSE} = 95,4 \text{ Mg ha}^{-1}$ (45%), comprovando que esta técnica apresentou-se melhor para as condições deste estudo. O modelo *Random Forest* também apresentou o melhor resultado ($r^2 = 0,73$ e $\text{RMSE} = 15\%$) em Kattenborn et al. (2015), no estudo de mapeamento de biomassa florestal de Floresta Temperada na Alemanha, Karlsruhe. No ranqueamento das variáveis preditoras em função da sua importância, a banda 4 (*Red-Edge*) apresentou a maior importância no modelo ajustado (Figura 3). Evidenciando mais uma vez a sensibilidade desta banda da região do vermelho da constelação do satélite *RapidEye* as variações existentes na vegetação do tipo tropical (Argoty et al., 2012). Seguida por esta, a segunda maior variável de importância para o modelo de *Random Forest* foi a razão entre as bandas *Red-Edge* e do azul (*b4_b1*). A terceira variável mais importante para o modelo foi a banda verde da região do visível (*b2*).

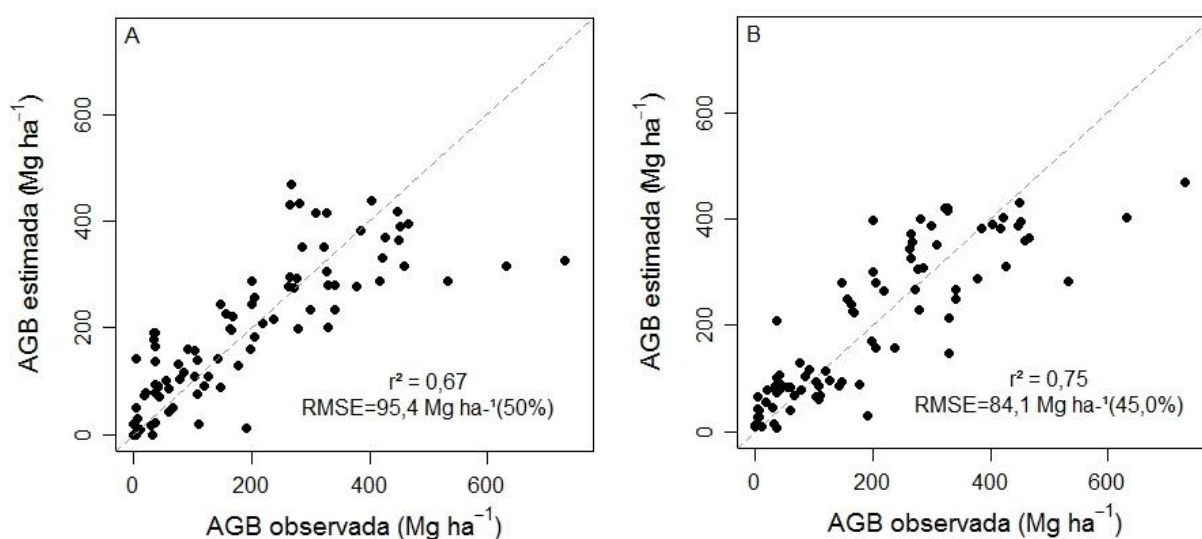


Figura 2. Valores observados x estimados de Biomassa Área (AGB, Mg ha^{-1}) para a FLONA Nacional do Tapajós a partir de dados do satélite *RapidEye*, (A) técnicas de regressão linear múltipla e (B) e modelo *Random Forest*.




Figura 3 – Importância das variáveis preditoras no modelo *Random Forest* de estimativa de Biomassa Aérea da Floresta Nacional do Tapajós.

4. Conclusões

Os dados do satélite *RapidEye* podem ser utilizados com segurança para estimar os valores de Biomassa Aérea (AGB) da Floresta Nacional do Tapajós.

O modelo de estimativa de biomassa ajustado pela técnica de *Random Forest* apresentou melhor desempenho do que o modelo ajustado pela regressão linear múltipla.

A variáveis preditoras com maior importância no modelo *Random Forest* foram a banda espectral do *Red-Edge*, seguidas pela razão entre as bandas 4 (*Red-Edge*) e 1 (azul) e pela banda verde (b2) da região do visível.

Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq / MCTI, Expedição Científica 010301 / 2009-7) e ao Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio / MMA, Processo 20591-2 do SISBIO) para autorizações de pesquisa. O escritório de Santarém do Experimento de Biosfera-Atmosfera em Grande Escala na Amazônia (LBA) por fornecer apoio logístico. Também agradecem a Edilson Oliveira (UFAC) e aos assistentes locais Jony Oliveira, Raimundo dos Santos, Iracélio Silva e Emerson Pedroso pela inestimável ajuda com as aquisições de campo.

Referências Bibliográficas

Argoty, F.; Cifuentes, M.; Imbach, P.; Vilchez, S.; Casanoves, F.; Ibrahim, M.; Vierling, L. Quantification of forest carbon degradation in Nicaragua using RapidEye re-mote sensing data: El Cuá and Wiwili case studies. **AGU fall meeting...** 2012. Disponível em: < <http://adsabs.harvard.edu/abs/2012AGUFM.B41E0341A>>. Acesso em 10 de novembro de 2016.

Aricak, B.; Bulut, A.; Altunel, A.; Sakici, O. Estimating above-ground carbon biomass using satellite image reflection values: a case study in camyazi forest directorate, Turkey. **Šumarski list**, v.139, n.7-8, p.369-376, 2015.

Baccini, A.; Goetz, S.J.; Walker, W.S.; Laporte, N.T.; Sun, M.; Sulla-Menasche, D.; Hackler, J.; Beck, P.S.A.; Dubayah, R.; Friedl, M.A.; Houghton, R.A. Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. **Nature Climate Change**, v.2, p.182–185, 2012.

Benítez, F. L.; Anderson, L. O.; Formaggio, A. R. Evaluation of geostatistical techniques to estimate the spatial distribution of aboveground biomass in the Amazon rainforest using high-resolution remote sensing data. **Acta Amazonica**, v. 46, n. 2, p. 151-160, 2016.

Bindel, M.; Hese, S.; Berger, C.; Schullius, C. Evaluation of red-edge spectral information for biotope mapping using RapidEye. Proc. SPIE 8174, Remote Sensing for Agriculture, Ecosystems, and Hydrology XIII, 81740X (October 07, 2011).

Breiman, L. Random forests. 2001. Disponível em: <<https://www.stat.berkeley.edu/~breiman/randomforest2001.pdf>>. Acesso em: 28 outubro. 2016

Chave, J.; Andalo, C.; Brown, S.; Cairns, M. a; Chambers, J. Q.; Eamus, D.; Fölster, H.; Fromard, F.; Higuchi, N.; Kira, T.; Lescure, J.-P.; Nelson, B. W.; Ogawa, H.; Puig, H.; Riéra, B.; Yamakura, T. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecologia**, v. 145, p. 87–99, 2005.

Chave, J.; Muller-Landau, H.C.; Baker, T.R.; Easdale, T.a; ter Steege, H.; Webb, C.O. Regional and phylogenetic variation of wood density across 2456 Neotropical tree species. **Ecological Applications**, v. 16, n. 6, p. 2356–2367, 2016.

Chave, J.; Réjou-Méchain, M.; Búrquez, A.; Chidumayo, E.; Colgan, M. S.; Delitti, W. B. C.; Duque, A.; Eid, T.; Fearnside, P. M.; Goodman, R. C.; Henry, M.; Martínez-Yrizar, A.; Mugasha, W. a; Muller-Landau, H. C.; Mencuccini, M.; Nelson, B. W.; Ngomanda, A.; Nogueira, E. M.; Ortiz-Malavassi, E.; Pélissier, R.; Ploton, P.; Ryan, C. M.; Saldarriaga, J. G.; Vieilledent, G. Improved allometric models to estimate the aboveground biomass of tropical trees. **Global Change Biological**, v. 20, n. 10, p. 3177-3190, 2014.

Du, H.; Cui, R.; Zhou, G.; Shi, Y.; Xu, X.; Fan, W.; Lu, Y. The responses of Moso Bamboo (*Phyllostachys heterocycla var. pubescens*) forest aboveground biomass to Landsat TM spectral reflectance and NDVI. **Acta Ecologica Sinica**, v.30, n. 5, p.257-263, 2010.

Hajek, F.; Ventresca, M.J.; Scriven, J.; Castrp, A. Regime-building for REDD+: evidence from a cluster of local initiatives in south-eastern Peru. **Environmental Science and Policy**, v.14, n. 2, p.201-215, 2011.

Harris, N.L.; Brown, S.; Hagen, S.C.; Saatchi, S.S.; Petrova, S.; et al. Baseline map of carbon emissions from deforestation in tropical regions. **Science**, v. 336, p. 1573–1575, 2012.

Houghton, R.A., Hall, F., e Goetz, S.J. Importance of biomass in the global carbon cycle. **Journal of Geophysical Research**. v.113, n. 2, p. 1-13, 2009.

IBAMA (Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis) Floresta Nacional do Tapajós-Plano de Manejo. IBAMA, Belterra; 2004. 38.

Keller, M.; Palace, M.; Hurtt, G. Biomass estimation in the Tapajós National Forest, Brazil examination of sampling and allometric uncertainties. **Forest Ecology Management**. v. 154, n. 3, p. 371–382, 2001.

Kattenborn, T.; Maack, J.; Faßnacht, F.; Enßle, F.; Ermer, J.; Koch, B. Corrigendum to Mapping forest biomass from space – Fusion of hyperspectral EO1-hyperion data and Tandem-X and WorldView-2 canopy height models. **International Journal of Applied Earth Observation and Geoinformation**, v. 41, n. 35, p. 359-367, 2015.

Neeff, T. e Santos, J. R. A growth model for secondary forest in Central Amazonia. **Forest Ecology Management**. v. 216, n. 1-3, p. 270–282, 2005.

Nelson, B. W.; Mesquita, R.; Pereira, J. L. .; Garcia Aquino de Souza, S.; Teixeira Batista, G.; Bovino Couto, L. Allometric regressions for improved estimate of secondary forest biomass in the central Amazon. **Forest Ecology Management**. v. 117, n. 1-3, p. 149–167, 1999.

Observatório Do Clima. Documento síntese [recurso eletrônico] : análise das emissões de GEE no Brasil (1970-2013) e suas implicações para políticas públicas / Governos Locais pela Sustentabilidade (ICLEI). [et al.]. – São Paulo : 2015. 52 p.

Pan, Y.; Birdsey, R.A.; Fang, J.; Houghton, R.; Kauppi, P.E.; Kurz, W.A.; Phillips, O.L.; Shvidenko, A.; Lewis, S.L.; Canadell, J.G. A large and persistent carbon sink in the world's forests. **Science**, v. 333, n. 6045, p. 988–993, 2011.

Powell, S.L.; Cohen, W.B.; Healey, S.P.; Keneedy, R.E.; Moisen, G.G.; Pierce, K.B.; Ohmann, J.L. Quantification of live aboveground forest biomass dynamics with Landsat time-series and field inventory data: a comparison of empirical modeling approaches. **Remote Sensing of Environment**, v.114, n. 5, p.1053-1068, 2010.

Rana, P.; Tokola, T.; Korhonen, L.; Xu, Q.; Kumpula, T.; Vihervaara, P.; Mononen, L. Training area concept in a two-phase biomass inventory using airborne laser scanning and RapidEye satellite data. **Remote Sensing**, v. 6, n. 1, p. 285–309, 2014.

R Core Team. R Foundation for Statistical Computing. R: A language and environment for statistical computing. Disponível em: <Disponível em: <http://www.R-project.org/>>. Acesso em: 14 out. 2016.

Reyes, G.; Brown, S.; Chapman, J.; Lugo, A. **Wood densities of tropical tree species**; 1992.

Van Laar, A. e Akça, A. **Forest Mensuration**; Managing Forest Ecosystems; Springer Netherlands: Dordrecht, 2007; Vol. 13.

Veloso, R.B; Rangel Filho, A.L.R.; Lima, J.C.A. Classificação da vegetação brasileira, adaptada a um sistema universal. Rio de Janeiro: IBGE, 124 p.; 1991.