

REGRESSÃO GEOGRAFICAMENTE PONDERADA APLICADA À ESTIMATIVA DE BIOMASSA ACIMA DO SOLO NA FLORESTA AMAZÔNICA UTILIZANDO SENSORIAMENTO REMOTO DE ALTA RESOLUÇÃO

GEOGRAPHICALLY WEIGHTED REGRESSION FOR ESTIMATING ABOVEGROUND BIOMASS IN THE AMAZON RAINFOREST BY HIGH-RESOLUTION REMOTE SENSING DATA

Fátima L. Benítez Ramírez¹, Liana O. Anderson^{2,1}, Antonio R. Formaggio¹, Clotilde P. F. dos Santos³

¹ Instituto Nacional de Pesquisas Espaciais - INPE, Av. dos Astronautas, 1758, 12.227-010 - São José dos Campos, SP, Brasil, fatima@dsr.inpe.br, liana@dsr.inpe.br, formag@dsr.inpe.br

² Environmental Change Institute, University of Oxford, Oxford, OX1 3QY, UK

³ Fundação de Ciência, Aplicações e Tecnologia Espaciais – FUNCATE, Av. Dr. João Guilhermino, 429 - São José dos Campos, SP, Brasil, cferri@funcate.org.br

RESUMO

A Amazônia representa a maior área de floresta tropical úmida do Planeta, onde grandes quantidades de carbono são armazenadas na sua biomassa. Estimativas de biomassa nesta região variam significativamente dependendo da abordagem aplicada e do conjunto de dados utilizados para sua modelagem. Assim, neste trabalho, foram aplicados dois tipos de abordagens para estimar espacialmente a biomassa acima do solo (BAS) utilizando conjuntamente informação coletada em campo, dados de sensoriamento remoto de alta resolução (RapidEye) e variáveis ambientais para uma área teste na Amazônia equatoriana. A primeira abordagem corresponde a uma regressão por mínimos quadrados ordinária (RMQO) e a segunda uma regressão geograficamente ponderada (RGP). Os resultados destas técnicas foram comparados estatisticamente, colocando à RGP sobre a RMQO. Assim, 75% da BAS foi explicada pela combinação de dados de sensoriamento remoto e variáveis ambientais através da RGP. Os próximos passos, serão a aplicação de uma técnica híbrida, que combina a RGP com a Krigagem, com o intuito de espacializar a BAS para toda a área de estudo. Espera-se que o método híbrido RGPK minimize os erros de predição depois de adicionar a componente estocástica (resíduos interpolados) à RGP.

Palavras-chave: Biomassa acima do solo, Regressão geograficamente ponderada, Regressão geograficamente ponderada krigagem, RedEdge, Emissões.

ABSTRACT

The Amazon is the largest area of tropical rainforest on the Planet, where large amounts of carbon are stored in their biomass. Biomass estimates in this region vary significantly depending on the applied approach and the data set used for modeling it. So, in this paper, two types of approaches were applied to estimate aboveground biomass (AGB) using field observation of biomass, high-resolution remote sensing data (RapidEye) and environmental variables in a test area from Ecuadorian Amazon. The first approach corresponds to a common global regression (OLQ) and the second a geographically weighted regression (GWR). The results of these techniques were statistically compared, where the GWR improved the model fitting. Thus, 75% of the AGB was explained by the combination of remote sensing data and environmental variables through GWR. The next procedures, will be the application of a hybrid technique that combines the GWR with Kriging, aiming the spatialization of AGB in the study area. Thus, it is expected that the hybrid method GWRK minimizes prediction errors after adding the stochastic component (interpolated residues) to the GWR.

Keywords: Aboveground biomass, geographically weighted regression, geographically weighted regression kriging, RedEdge, emissions.

INTRODUÇÃO

As florestas contêm cerca de 80% dos estoques globais de carbono desempenhando um papel importante no ciclo de carbono (HOUGHTON, 2005). As florestas tropicais e boreais são as que armazenam maior quantidade de este elemento, 471 ± 93 PgC e 272 ± 23 PgC, respectivamente (PAN *et al.*, 2011). A diferença fundamental entre elas se mostra na distribuição de carbono em seus reservatórios, onde, as florestas tropicais armazenam maior percentagem de carbono na biomassa, enquanto as florestas boreais armazenam uma maior percentagem no solo (PAN *et al.*, 2011).

A Amazônia representa a maior área de floresta tropical úmida do Planeta, acolhe uma grande biodiversidade e tem uma influência considerável sobre o clima regional e global (MALHI *et al.*, 2008). A variação das estimativas de biomassa e sua distribuição espacial nesta região são responsáveis pelas incertezas imersas na estimativa de estoques de carbono e, conseqüentemente, no seu fluxo líquido.

As estimativas de biomassa acima do solo (BAS) existentes são provenientes de inventários florestais nacionais ou regionais que fornecem informação precisa em um nível local, no entanto, em escalas espaciais mais amplas esta informação vai perdendo essa precisão (BACCINI *et al.*, 2008). O desenvolvimento de ferramentas e modelos baseados em dados de sensoriamento remoto tem permitido realizar o “*scale up*” ou extrapolar a informação coletada em campo para escalas maiores (BACCINI *et al.*, 2012; SAATCHI *et al.*, 2011). No entanto, o mapeamento da BAS na Amazônia baseado em sensoriamento remoto é um trabalho desafiador, posto que existe a saturação desde dados em áreas de florestas densas.

Diversas técnicas estatísticas têm sido desenvolvidas para modelar variáveis ambientais que podem variar através do espaço geográfico. Assim, a Regressão Geograficamente Ponderada (RGP) é uma ferramenta poderosa na exploração da heterogeneidade espacial, através da qual se estimam parâmetros para cada amostra do conjunto de dados. Esta técnica, considera a relação de não-estacionaridade e fornece um entendimento detalhado da variação espacial (FOTHERINGHAM *et al.*, 2002) e, assim, torna-se uma ferramenta muito atraente para a modelagem de biomassa através de sensoriamento remoto (PROPASTIN, 2012).

Neste contexto, o objetivo principal do presente trabalho é espacializar a distribuição da BAS utilizando ferramentas geoestatísticas, via os seguintes objetivos específicos: (i) Utilizar a RGP e a regressão por mínimos quadrados ordinária (RMQO), e (ii) comparar as estimativas da RGP com aquelas obtidas a partir da RMQO.

Neste trabalho, são utilizadas imagens satelitais de alta resolução espacial (Rapideye) para estimar BAS na floresta amazônica em uma escala regional, além de informação espacial associada a formações vegetais, solo, altitude e biomassa acima do solo.

Área de estudo

A área de estudo abrange 3,448,749 ha da floresta tropical úmida amazônica das províncias de Sucumbios e Orellana, Equador. Sua localização geográfica está entre as coordenadas $1^{\circ} 12' S$ e $0^{\circ} 39' N$ de latitude e $77^{\circ} 58' O$ e $75^{\circ} 9' O$ de longitude (Figura 1a). A precipitação média anual varia entre 2800-5000 mm, e sua temperatura é relativamente uniforme com uma média anual de $25^{\circ} C$. Na região distinguem-se quatro grandes tipos de formações vegetais: florestas de terra firme, florestas inundáveis por rios de origem amazônica e andina, florestas inundadas (localmente conhecidas como “Moretales”) e florestas em sistemas lacustres-ripárias de águas negras. As áreas com perturbação antrópica, rios e solo exposto não foram levadas em consideração neste estudo. Neste trabalho, avalia-se a metodologia para uma área piloto, de forma a testar sua adequação (Figura 1b). Pretende-se ampliar a metodologia para recobrir as duas províncias citadas acima na segunda fase de desenvolvimento deste estudo.

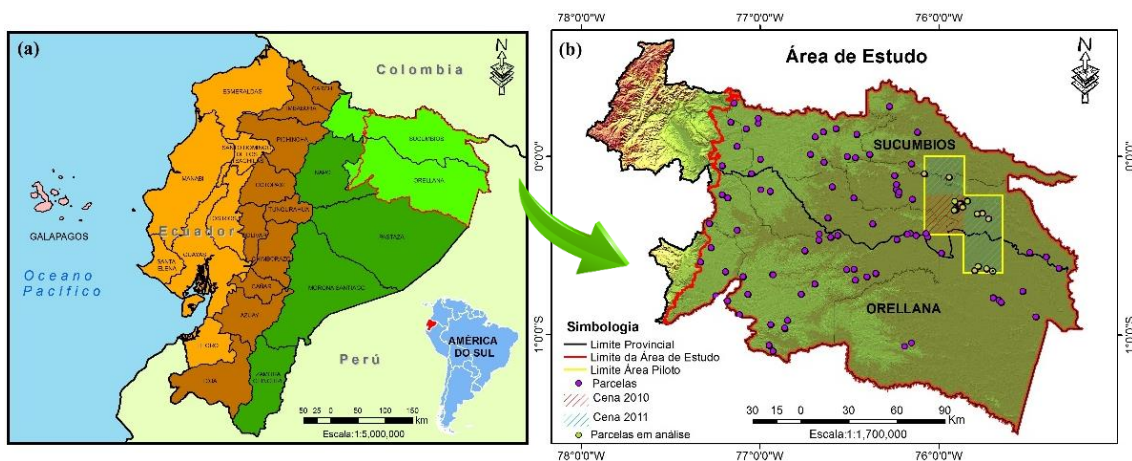


Figura 1. (a) Localização geográfica da área de estudo, (b) localização geográfica da área piloto e distribuição espacial das parcelas com dados de campo.

MATERIAIS

Dados de Biomassa

Em novembro de 2013 foram publicados os dados do primeiros Inventário Florestal Nacional do Equador. Os trabalhos de campo na Amazônia equatoriana iniciaram no ano de 2011, onde foram distribuídas 484 parcelas em diferentes estratos de vegetação natural. Em cada parcela foram feitas medições de vários parâmetros da estrutura florestal (diâmetro à altura do peito, altura, densidade de madeira, entre outro) e a partir deles foi calculada a BAS utilizando equações alométricas descritas por Chave *et al.* (2005).

Para a área piloto abordada neste estudo foram selecionadas 52 parcelas amostrais de BAS com um tamanho aproximado de 0.25 ha. cada. No total, encontram-se 277 parcelas de campo que serão utilizadas nas próximas fases do estudo.

Dados de Sensoriamento Remoto

Foram utilizadas quatro cenas Rapideye, sendo uma de setembro 2010 e três de janeiro 2011 (Figura 1b) disponibilizadas pelo Ministério do Ambiente Equatoriano (MAE). Estas cenas apresentam um nível de processamento 3A, ou seja, imagens ortoretificadas. As imagens Rapideye tem uma resolução espacial de 5 m. em todas suas bandas espectrais, e sua característica principal é possuir uma banda espectral chamada *RedEdge* localizada entre a banda vermelha e o infravermelho próximo. Esta banda possibilita medir a variação da vegetação, permitindo o discernimento de espécies e o monitoramento do vigor da vegetação.

Cada uma destas imagens passou por um processo de correção atmosférica, utilizando a ferramenta FLAASH (Envi 5.0) que incorpora o modelo de transferência radiativa MODTRAN4 (MATTHEW *et al.*, 2000), para obter dados de reflectância em cada banda e para cada cena.

Em seguida, foram calculados cinco índices de vegetação: índice de vegetação por diferença normalizada (NDVI), índice de vegetação ajustado ao solo (SAVI), índice de vegetação ajustado ao solo modificado (MSAVI), Green-NDVI (GNDVI) e Green-Blue-NDVI (GBNDVI), sendo que os três últimos têm demonstrados ser melhores estimadores do índice da área foliar (LAI) em coberturas densas (QI, 1994; WANG *et al.*, 2007). O NDVI e o MSAVI foram modificados, agregando a banda *RedEdge* para o seu cálculo. Finalmente, foram gerados 11 índices de vegetação como variáveis independentes. As equações utilizadas para o cálculo de todos eles, são detalhadas na Tabela 1.

Tabela 1. Equações utilizadas no cálculo de vários índices de vegetação utilizados neste trabalho.

Índice	Equação	Fonte
NDVI_1	$(IVP - V) / (IVP + V)$	Rouse <i>et al.</i> (1974)
NDVI_2	$(RedEdge - V) / (RedEdge + V)$	Sousa C. H. R. <i>et al.</i> (2012)
NDVI_3	$(IVP - RedEdge) / (IVP + RedEdge)$	Sims, D.; Gamon, J. (2002)
NDVI_RedEdge	$[IVP - (V + RedEdge)] / [IVP + (V + RedEdge)]$	Martin <i>et al.</i> (2012)
SAVI	$(1 + L) * [(IVP - V) / (IVP + V + L)]$, L=0,5	Huete (1988)
MSAVI	$0,5 * [(2IVP + 1) - \sqrt{\{(2IVP + 1)^2 - 8(IVP - V)\}}]$	Qi <i>et al.</i> (1994)
MSAVI_RedEdge1	$0,5 * [(2IVP + 1) - \sqrt{\{(2IVP + 1)^2 - 8(IVP - (V + RedEdge))\}}]$	Este estudo
MSAVI_RedEdge2	$0,5 * [(2RedEdge + 1) - \sqrt{\{(2RedEdge + 1)^2 - 8(RedEdge - V)\}}]$	Este estudo
MSAVI_RedEdge3	$0,5 * [(2IVP + 1) - \sqrt{\{(2IVP + 1)^2 - 8(IVP - RedEdge)\}}]$	Este estudo
GNDVI	$(IVP - G) / (IVP + G)$	Gitelson <i>et al.</i> (1996)
GBNDVI	$[IVP - (G + B)] / [IVP + (G + B)]$	Wang <i>et al.</i> (2007)

Para obter dados de altitude em cada parcela foi utilizado o modelo digital de elevação Aster com uma resolução espacial de 30 m.

Dados de Formações Vegetais e de Solos

Informações temáticas sobre formações vegetais e solos foram proporcionada pelo MAE em escalas 1:100.000 e 1:200.000 respectivamente. Dentro da área piloto podem-se distinguir sete formações vegetais: floresta inundável da planície aluvial dos rios de origem amazônica, floresta inundável da planície aluvial dos rios de origem andina e das cordilheiras, floresta inundável e vegetação lacustre-riparia de águas negras da Amazônia, floresta inundada da planície aluvial da Amazônia, floresta inundada de palmas da planície aluvial da Amazônia, floresta sempreverde de terras baixas do Aguarico-Putumayo-Caquetá, herbazal inundado lacustre-ripario da planície aluvial da Amazônia. Na área piloto são distinguidos três tipos de solos que correspondem à orden *Entisol*, *Histosol* e *Inceptisol*.

MÉTODOS

Estimativas de Biomassa acima do solo (BAS)

Primeiramente, para cada amostra, foi extraído o valor médio de cada índice de vegetação derivado de uma janela de 13x13 pixels (65m x 65m) sobre a posição central de cada pixel onde a amostra encontra-se posicionada. Em seguida, foram aplicados os modelos de regressão linear ordinária (RMQO) e regressão geograficamente ponderada adaptativa (RGPA) e fixa (RGPF) para estimar BAS a partir de 11 índices de vegetação, duas variáveis ambientais (formações vegetais e solo) e a altitude, totalizando 14 variáveis explicativas. Este procedimento foi aplicado para cada variável independente e os seus resultados foram comparados estatisticamente.

Regressão Geograficamente Ponderada (RGP)

A RGP é uma abordagem recente e avançada para a modelagem espacial de processos heterogêneos (KUMAR *et al.*, 2012), que permite estimar parâmetros individuais para cada localização observada, e assim, não assumir que um único modelo pode ser ajustado para toda a área de estudo. O modelo da RGP é considerado pela equação detalhada a seguir (FOTHERINGHAM *et al.*, 2002):

$$\hat{Y} = \hat{\beta}_0(x, y) + \hat{\beta}_1(x, y)X_1 + \dots + \hat{\beta}_n(x, y)X_n + \varepsilon$$

onde \hat{Y} é a variável dependente (neste caso representa a BAS), $X_1 a X_n$ são as variáveis independentes ou explicativas, $\hat{\beta}_0$ é o intercepto, $\hat{\beta}_1 a \hat{\beta}_n$ são os coeficientes da regressão, ε é o residual, x e y representam as coordenadas geográficas da amostra.

A ideia básica desta técnica é explorar como as relações entre variável dependente e variáveis independentes podem variar no espaço geográfico. Para isto, uma janela exploratória vai se movimentando por cada amostra do conjunto de dados, trabalhando em sequência através de todos eles. Quando a janela posiciona-se em um ponto amostral, todos os outros pontos que estão em seu torno e dentro da janela são identificados. Assim, o modelo de regressão é ajustado a esse subconjunto de dados, fornecendo maior peso para os pontos que estão mais próximos ao ponto amostral central (função Kernel).

A calibração do modelo de regressão está baseada na seleção do método espacial kernel, que depende basicamente da distribuição dos dados sobre o espaço a ser analisado: se a distribuição for uniforme o método kernel com distância fixa é adequando. Já em uma distribuição não uniforme é melhor utilizar o método adaptativo, onde a distância vai mudar de acordo com a densidade espacial das amostras, assim, a largura da banda torna-se em função do número de vizinhos mais próximos e, cada estimativa local é baseada no mesmo número de vizinhos. Para este trabalho, a análise foi testada com os dois métodos.

A exatidão da previsão do modelo depende fortemente da função de ponderação e da largura da janela (bandwidth) selecionada (PROPASTIN, 2012). Esta seleção pode ser feita através de uma validação cruzada ou da minimização do critério de informação Akaike (AIC). No presente estudo, foi utilizada a função kernel Gaussiana para ajustar o modelo da RGP e o AIC para calibrar o modelo em relação à largura da banda.

Modelagem Híbrida (RGPK) da distribuição espacial da biomassa acima do solo

A RGPK é uma técnica de predição onde os resíduos da regressão geograficamente ponderada são interpolados através de uma krigagem ordinária. Ambas as abordagens são modeladas de forma separada para finalmente realizar uma sobreposição espacial e, assim, obter os valores estimados da variável dependente (Figura 2).

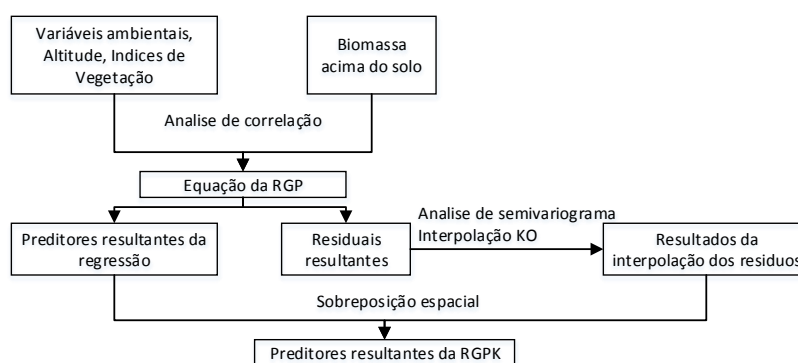


Figura 2. Fluxograma da RGPK para o caso em estudo.

RESULTADOS

Estimativas de biomassa acima do solo

As estatísticas descritivas e o diagnóstico dos modelos testados são apresentados na Tabela 2. Todos os modelos com exceção de dois ($RMQO_{GBNDVI}$, $RGPA_{GBNDVI}$) foram estatisticamente significantes ($p < 0,05$). Os índices de vegetação, calculados a partir da reflectância no infravermelho próximo e na banda RedEdge ($NDVI_3$, $MSAVI_{red3}$) apresentaram maior correlação com o conjunto de dados de BAS. Os critérios AIC e RSS são utilizados para avaliar a adequação dos modelos e, assim, modelos com valores baixos de AIC e

RSS são considerados os melhores em ajustar-se aos dados. Os valores mínimos de AIC e RSS aplicando a RMQO foram de 644,78 e 687200,2 respectivamente, alcançados pelo modelo desenvolvido a partir do NDVI_3. Este modelo explicou 35% da BAS.

Tabela. 2. Estatísticas descritivas dos modelos preditivos de biomassa acima do solo utilizando RMQO e RGP.

Model _{PREDITORES}	R ²	No. Vizinhos	Bandwidth (m)	RSS	AIC	p-valor
RGPF _{VEG}	0.80	n/a	8138.089	202823.5	587.01	p<0.001
RGPA _{VEG}	0.68	37	n/a	326830.1	605.11	p<0.001
RGPF _{NDVI_RedEdge}	0.65	n/a	7166.48	350488.1	614.91	p<0.05
RGPF _{MSAVL_red1}	0.65	n/a	7166.48	354975.5	615.54	p<0.05
RGPF _{NDVI_3}	0.65	n/a	7383.06	356305.4	615.52	p<0.05
RGPF _{MSAVL_red3}	0.64	n/a	7370.281	359242.4	615.93	p<0.05
RGPF _{SAVI}	0.64	n/a	7078.87	363455.6	617.1	p<0.05
RGPF _{NDVI_1}	0.64	n/a	7078.87	363484.8	617.1	p<0.05
RGPF _{MSAVI}	0.64	n/a	7099.552	367267.1	617.59	p<0.05
RMQO _{VEG}	0.63	---	---	371369.5	615	p<0.001
RGPF _{NDVI_2}	0.57	n/a	7983.55	434144.3	626.08	p<0.05
RGPF _{MSAVL_red2}	0.57	n/a	8029.797	437109.4	626.38	p<0.05
RGPF _{SOLO}	0.55	n/a	12712.62	449914.6	625.04	p<0.05
RGPA _{NDVI_3}	0.49	21	n/a	513545.5	629.62	p<0.001
RGPA _{MSAVL_red3}	0.49	21	n/a	518150.2	630.1	p<0.001
RGPA _{SOLO}	0.49	21	n/a	516992.5	630.19	p<0.001
RGPF _{GNDVI}	0.49	n/a	9217.99	512779.8	633.6	p<0.05
RGPA _{NDVI_RedEdge}	0.48	21	n/a	521724.3	630.41	p<0.001
RGPA _{MSAVL_red1}	0.48	21	n/a	526934.4	630.95	p<0.001
RGPF _{GBNDVI}	0.48	n/a	7962.869	527505.8	635.73	p<0.05
RGPA _{SAVI}	0.45	21	n/a	560151	634.12	p<0.001
RGPA _{NDVI_1}	0.45	21	n/a	560234.6	634.12	p<0.001
RGPA _{MSAVI}	0.44	21	n/a	562271.3	634.33	p<0.001
RGPA _{ASTER_dem}	0.44	21	n/a	563485.3	635.53	p<0.05
RGPF _{ASTER_dem}	0.38	n/a	20506.18	630529.3	640.47	p<0.001
RMQO _{NDVI_3}	0.35	---	---	651287.7	644.21	p<0.001
RMQO _{MSAVL_red3}	0.35	---	---	654193.7	644.45	p<0.001
RMQO _{SOLO}	0.34	---	---	661334	645.01	p<0.001
RMQO _{NDVI_RedEdge}	0.33	---	---	677937	646.29	p<0.001
RMQO _{MSAVL_red1}	0.33	---	---	679664.9	646.43	p<0.001
RGPA _{NDVI_2}	0.32	21	n/a	687200.2	644.78	p<0.05
RGPA _{GNDVI}	0.31	21	n/a	697062.6	645.69	p<0.05
RGPA _{MSAVL_red2}	0.30	26	n/a	709195.9	645.68	p<0.001
RMQO _{MSAVI}	0.28	---	---	728556.6	650.04	p<0.001
RMQO _{SAVI}	0.28	---	---	729110.3	650.08	p<0.001
RMQO _{NDVI_1}	0.28	---	---	729197.1	650.08	p<0.001
RGPA _{GBNDVI}	0.22	21	n/a	782984.1	651.66	Não significativa
RMQO _{MSAVL_red2}	0.17	---	---	841048.7	657.51	p<0.05
RMQO _{NDVI_2}	0.16	---	---	846434.1	657.84	p<0.05
RMQO _{GNDVI}	0.14	---	---	871034.1	659.33	p<0.05
RMQO _{ASTER_dem}	0.10	---	---	906204.4	661.39	p<0.05
RMQO _{GBNDVI}	0.03	---	---	974404.9	665.16	Não significativa

Observou-se que o valor R^2 aumenta da RMQO para a RGP em todas as variáveis, confirmando a maior potencialidade da RGP na estimativa de BAS. Assim, embora os resultados do modelo RMQO sejam estatisticamente significativos, apenas conseguem explicar 35% da variação espacial da biomassa em relação aos dados de sensoriamento remoto. Já, a RGP consegue explicar 65% das variações locais da BAS a partir do NDVI_RedEdge.

Em todas as variáveis analisadas observam-se melhoras significativas no ajuste dos modelos da RGPF sobre a RGPA, com exceção da altitude. A variável associada às formações vegetais mostrou a maior correlação com a BAS, revelando que quase 80% da biomassa é explicada pelo tipo de floresta.

Através de uma análise exploratória da regressão foram avaliadas todas as possíveis combinações das variáveis independentes que melhor conseguiram explicar a variável dependente, levando em consideração a multicolinearidade entre elas e sua não estacionaridade local. Assim, combinando as variáveis solo, vegetação e os índices NDVI_2 e GBNDVI, 72% da biomassa pode ser explicada através de uma regressão linear ordinária e um 75% através da regressão geograficamente ponderada adaptativa. As estatísticas descritivas dos parâmetros estimados no modelo, utilizando as duas abordagens, são apresentadas na Tabela 3.

Tabela 3. Estatísticas descritivas dos parâmetros estimados para o modelo RMQO e RGPA

Parâmetro	Modelo RMQO			Modelo RGPA					
	Estimativa	SD	p-valor	Min	1Q	Mediana	3Q	Max	p-valor
Interceptor	1,017,347	217.936	p<0.001	827.6	896.7	925.8	1007	1026	Não significativa
Solo	-85,685	21.897	p<0.001	-88.72	-87.33	-70.09	-65.27	-53.54	p<0.05
Veg.	-30.197	3.905	p<0.001	-37.36	-35.14	-34.25	-29.66	-27.99	p<0.001
NDVI_2	-1252.35	480.931	p<0.05	-1256	-1235	-1009	-933.6	-772.1	p<0.05
GBNDVI	542.225	226.463	p<0.05	396.3	440.2	458.4	526.3	531.2	Não significativa
R^2	0.72			0.75					

Observa-se na análise de resíduos uma melhor adequação da RGP em relação à RMQO (Figura 3a e 3b). Este fato indica que a maior parte da distribuição da biomassa é explicada por sua relação local com as variáveis independentes.




Figura 3. Resíduos do modelo de Regressão: a) RGP, b) RMQO. c) BAS estimada na área piloto a partir da RMQO.

A partir do modelo de melhor ajuste na estimativa de BAS ($BAS = \hat{\beta}_0 + \hat{\beta}_1 Solo + \hat{\beta}_2 Veg. + \hat{\beta}_3 NDVI_2 + \hat{\beta}_4 GBNDVI + \varepsilon$), foi realizada a modelagem da sua distribuição espacial na área piloto, apenas utilizando a RMQO (Figura 3c), já que fornece resultados globais para a modelagem. Observa-se que existe uma diferença nos resultados entre as duas cenas utilizadas, de forma a criar um padrão artificial na distribuição espacial da biomassa. Atribui-se tal artefato à presença de

bruma no conjunto de imagens localizadas na região sudeste da área de estudo, além dos efeitos de diferenças nos ângulos de aquisição, geometria sensor-sol-alvo e datas distintas. Isto revela que somente a transformação para reflectância de superfície dos números digitais não é suficiente para deixar os dados intercomparáveis espectralmente entre as cenas. Assim, é importante que as imagens passem por um processo de normalização radiométrica, de forma a permitir a aplicação do mesmo modelo de regressão aos índices de vegetação para toda a área de estudo.

A RMQO produz valores de RMSE maiores que a RGP (127,5 e 69,3 respectivamente, neste estudo), o que indica que esta abordagem pode sub ou superestimar o conteúdo de BAS na região. Neste contexto, com o intuito de melhorar a distribuição espacial, pretende-se minimizar ainda mais os resíduos da RGP, aplicando uma interpolação de krigeagem sobre eles. Espera-se que o método híbrido RGPK minimize os erros de predição depois de adicionar a componente estocástica (resíduos interpolados) à RGP.

Finalmente, o propósito deste estudo é aplicar a metodologia desenvolvida para toda a área de estudo e assim, gerar um mapa que mostre a distribuição espacial da biomassa. Este produto será de grande utilidade para futuros estudos que incluam estimativas de emissões de carbono.

REFERÊNCIA

- BACCINI, A. *et al.* A first map of tropical Africa's above-ground biomass derived from satellite imagery. *Environmental Research Letters*, v. 3, n. 4, p. 1-9, 2008.
- BACCINI, A. *et al.* Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. *Nature Climate Change*, v. 2, n. 3, p. 182-185, 2012.
- CHAVE, J. *et al.* Tree allometry and improved estimation of carbon stocks and balance in tropical forests. *Oecologia*, v. 145, n. 1, p. 87-99, 2005.
- FOTHERINGHAM, A.S. *et al.* *Geographically Weighted Regression: The Analysis of Spatially Varying Relationships*. Chichester: Wiley, 2002.
- HOUGHTON, R. Aboveground Forest Biomass and the Global Carbon Balance. *Global Change Biology*, v. 11, n. 6, p. 945-958, 2005.
- HUETE, A.R. A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, v. 25, n. 3, p. 295-309, 1988.
- KUMAR, S. *et al.* A geographically weighted regression kriging approach for mapping soil organic carbon stock. *Geodema*, v. 189-190, p. 627-634, 2012.
- MALHI, Y. *et al.* Climate Change, Deforestation, and the Fate of the Amazon. *Science*, v. 319, n. 169, p. 168-172, 2008.
- MARTÍN, F. *et al.* RapidEye and the RedEdge band for modelling the vegetation and the recovery of the soil moisture. *Mapping*, n. 50, p. 10-20, 2012.
- MATTHEW M.W. *et al.* Status of atmospheric correction using a MODTRAN4-based algorithm. In: *SPIE Proceedings, Algorithms for Multispectral, Hyperspectral, and Ultraspectral Imagery VI*, v. 4049, p. 199-207, 2000.
- PROPASTIN, P. Modifying geographically weighted regression for estimating aboveground biomass in tropical rainforests by multispectral remote sensing data, v. 18, p. 82-90, 2012.
- QI, J. *et al.* A modified soil adjusted vegetation index. *Remote Sensing of Environment*, v. 48, n. 2, p. 119-126, 1994.
- ROUSE, J.W. *et al.* Monitoring vegetation systems in the Great Plains with ERTS. In: *ERTS SYMPOSIUM*, 3, 1973. Washington. NASA SP-351, v. 1, p. 309-317.
- SAATCHI, S. *et al.* Benchmark map of forest carbon stocks in tropical regions across three continents. *PNAS*, v. 108, n. 24, p. 9899-9904, 2011.

SIMS, D.A; GAMON, J.A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of Environment*, v. 81, p. 337-354, 2002.

SOUSA C.H.R. *et al.* Analysis of rapideye's red edge band for image segmentation and classification. In: *Proceedings of the 4th GEOBIA*, 4, 2012. Rio de Janeiro - Brazil. p. 518.