



Proposta de Ajuste de Altura Interferométrica para Modelo de Estimativa de Biomassa Interferometric Height Adjustment for Biomass Estimation Model

Carlos Alberto Pires de Castro-Filho^{1,2} & Edilson de Souza Bias¹

¹Universidade de Brasília (UnB), Instituto de Geociências, Programa de Pós-Graduação em Geociências Aplicadas e Geodinâmica, Campus Universitário Darcy Ribeiro, Instituto Central de Ciências – ICC, Ala Central, 70910-900, Brasília, DF, Brasil

²Diretoria de Serviço Geográfico, Quartel General do Exército, Bloco “F”, 1º

Andar, Setor Militar Urbano, 70630-901, Brasília, DF, Brasil

E-mails: carlos.pires.1976@gmail.com; edbias@unb.br

Recebido em: 06/03/2020 Aprovado em: 06/06/2020

DOI: http://doi.org/10.11137/2020_3_110_123

Resumo

A tecnologia de Radar de Abertura Sintética Interferométrica (InSAR), quando utilizada em diferentes comprimentos de onda, é capaz de gerar a altura interferométrica (H_{int}), calculada pela diferença aritmética entre o modelo digital de superfície (MDS) e o modelo digital do terreno (MDT). A H_{int} representa a altura da vegetação, visto que é o comprimento entre o terreno e o dossel da vegetação e, teoricamente, para áreas de solo exposto deve ter o valor estatisticamente igual a zero. O presente artigo tem por objetivo analisar a possibilidade de utilização de áreas identificadas como de solo exposto para ajustar dados InSAR, e consequentemente a H_{int} , visando a melhoria no modelo de estimativa de biomassa. A metodologia adotada inclui o uso de técnicas paramétricas e não paramétricas de busca de solução para definição dos parâmetros de ajuste da H_{int} sobre modelos matemáticos polinomiais e logarítmicos. Os melhores resultados foram obtidos com o modelo matemático logarítmico cujos parâmetros foram ajustados com a técnica do Gradiente Reduzido Generalizado. Entretanto, a análise dos resultados mostrou que não houve melhora significativa do coeficiente de correlação entre a biomassa florestal e a H_{int} original ($r = 0,7518$) e entre a biomassa florestal e a H_{int} ajustada ($r = 0,7564$).

Palavras-chave: RADAR; InSAR; Biomassa

Abstract

Interferometric Synthetic Aperture Radar (InSAR) technology, when used at different wavelengths, is capable of generating the interferometric height (H_{int}), calculated by the arithmetic difference between the digital surface model (DSM) and the digital terrain model (DTM). The H_{int} represents the height of the vegetation, since it is the length between the ground and the vegetation canopy and, theoretically, for exposed soil areas should be statistically equal to zero. This paper aims at analyzing the possibility of using exposed soil identified areas to adjust InSAR data, and consequently the H_{int} , looking forward to improving the biomass estimation model. The adopted methodology includes the use of parametric and nonparametric solution search techniques to define the H_{int} adjustment parameters on polynomial and logarithmic mathematical models. The best results were obtained with the logarithmic mathematical model which parameters were adjusted using the Generalized Reduced Gradient technique. However, analysis of the results showed that there was no significant improvement in the correlation coefficient between forest biomass and original H_{int} ($r = 0.7518$) and between forest biomass and adjusted H_{int} ($r = 0.7564$).

Keywords: RADAR; InSAR; Biomass

1 Introdução

A estimativa de biomassa florestal é tratada por pesquisadores, universidades e institutos que atuam nas áreas de geociências, em todo o mundo, como um tema de grande relevância, suprindo pesquisas nas áreas de meteorologia e ecologia e tendo fortes impactos econômicos. Segundo Zhang *et al.* (2017), o assunto encontra-se entre os mais pesquisados e publicados, entre os anos de 2010 e 2015, nos periódicos de sensoriamento remoto, sendo utilizado como palavra-chave, em média, em 95 artigos técnicos publicados anualmente.

Dentre as tecnologias de sensoriamento remoto, as de Radar de Abertura Sintética (SAR) possuem destaque na modelagem de biomassa florestal devido a sua capacidade de caracterizar a geometria da região imageada (Saatchi *et al.*, 2007). Esta caracterização, quando associada a tecnologia interferométrica, chamada de InSAR, constrói modelos numéricos de elevação referentes ao comprimento de onda aplicado.

As técnicas de InSAR, quando utilizadas em diferentes comprimentos de onda, são capazes de gerar a altura interferométrica (H_{int}). A H_{int} pode ser calculada pela diferença aritmética das bandas de comprimento de onda X, referente ao modelo digital de superfície (MDS), e P, referente ao modelo digital do terreno (MDT). Neste caso ela representa a altura da vegetação, visto que é o comprimento entre o terreno e o dossel da vegetação.

Apesar de existir correlação entre a H_{int} e a altura da vegetação, são observadas regiões que apresentam inconsistências referentes aos dados de banda X e P. Teoricamente, o valor da H_{int} em áreas de solo exposto deve ser estatisticamente igual a zero. Isto ocorre porque tanto o retroespalhamento da banda X, que possui o comprimento de onda médio de 3 cm, como da banda P, com comprimento de onda médio de 0,7m, devem ocorrer junto ao solo exposto da região florestal imageada. Porém, em alguns casos são identificadas áreas de solo exposto cujo valor da H_{int} é estatisticamente diferente de zero.

No Brasil, o Projeto “Radiografia da Amazônia” desenvolvido pela Diretoria do Serviço Geográfico do Exército (DSG), encontra-se mapeando uma vasta área de região florestal (1.800.000 km²) utilizando sensor de radar polarimétrico e interferométrico nas bandas X e P. Os dados polarimétricos, possibilitam a identificação e delimitação de regiões de solo exposto por meio de processos foto interpretativos ou por técnicas de classificação de imagens, como também, é possível observar que em algumas dessas regiões o valor de H_{int} é estatisticamente diferente de zero. Utilizando-se dessas premissas, o presente artigo tem por objetivo analisar a possibilidade de utilização de áreas identificadas como de solo exposto para ajustar dados InSAR, e consequentemente a H_{int} , visando a melhoria no

modelo de estimativa de biomassa para futuros cálculos com o uso de técnicas de aprendizado de máquina.

2 Fundamentação Teórica

2.1 Modelo Digital de Elevação, Modelo Digital de Superfície e Modelo Digital do Terreno

De acordo com Burrough (1986), o termo Modelo Digital do Terreno (MDT) foi primeiramente utilizado por Miller e LaFlamme em 1958 e se refere a um conjunto de pontos que modelam uma região de superfície do terreno por meio de dados altimétricos. Os dados do MDT são representados pelos valores das coordenadas nos eixos x, y e z, onde z, valor a ser modelado, é em função de x e y, ou seja, $z=f(x,y)$.

Atualmente, como consequência da evolução tecnológica, a definição clássica dos modelos tridimensionais que representam superfícies passou por alterações e recebeu uma série de termos distintos. Alguns órgãos brasileiros e internacionais apresentam diferentes definições, como: Modelo Digital de Elevação (MDE), Modelo Digital de Superfície (MDS) e, finalmente, Modelo Digital de Terreno (MDT). A conceituação de cada um deles pode ser observada na Tabela 1.

2.2 Biomassa Florestal

Biomassa florestal ou fitomassa é a quantidade, em unidade de massa, do material lenhoso contido em uma unidade de área de floresta (Araújo *et al.*, 1999). Além dos métodos *in loco* de estimativa de biomassa, outros métodos são realizados com o uso de sensores remotos, não havendo a necessidade de extensos trabalhos de campo, o que viabiliza financeiramente o levantamento de grandes áreas. Nestes casos busca-se relacionar as características representadas pelas imagens às características físicas medidas das árvores ou, diretamente, à biomassa existente na região imageada.

Diversos autores vêm buscando utilizar dados de SAR para modelar e, consequentemente, estimar a quantidade de biomassa em diversos tipos de florestas. Dentre esses autores, destacam-se os trabalhos de Pope *et al.* (1994), Santos *et al.* (2003), Saatchi *et al.* (2007), Debastiani *et al.* (2019) e Oliveira & Locks (2019).

2.3 Radar de Abertura Sintética Interferométrico com Aplicação na Estimativa de Biomassa

Juntamente aos dados polarimétricos, o potencial da informação interferométrica de um SAR para modelagem de biomassa em ambientes tropicais ainda possui vasta área de pesquisa. Gama (2007), ao buscar uma modelagem para estimar a biomassa em um povoamento de *Eucalyptus*, concluiu que os atributos que obtiveram melhores resultados foram provenientes dos produtos interferométricos.

Sigla	Definição	Orgão ou Instituição
MDE	Produto cartográfico obtido a partir de um modelo matemático que representa um fenômeno, de forma contínua, a partir de dados adequadamente estruturados e amostrados no mundo real.	Especificação Técnica para Produtos de Conjunto de Dados Geoespaciais (ET-PCDG), elaborada pela DSG (2016)
	Representação matemática computacional da distribuição de um fenômeno espacial que ocorre dentro de uma região da superfície terrestre.	Felgueiras (2004), do Instituto Nacional de Pesquisas Espaciais (INPE)
MDS	Produto obtido a partir de um modelo digital de elevações que representa o solo exposto e os acidentes naturais e/ou construídos pelo ser humano encontrados acima do solo (edificações, pontes, corte e aterro do terreno, vegetação, etc), de forma contínua e suavizada, a partir de dados adequadamente estruturados e amostrados do mundo real.	ET-PCDG (DSG, 2016); <i>European Space Agency</i> – ESA (Mouratidis, 2014); e <i>Japanese Space Agency</i> – Jaxa (JAXA, 2019)
	Modelo digital que representa as altitudes da superfície topográfica agregada aos elementos geográficos existentes sobre ela, como cobertura vegetal e edificações.	IBGE (2019)
MDT	O modelo representa o solo exposto, de forma contínua e suavizada, a partir de dados adequadamente estruturados e amostrados da superfície física da Terra.	ET-PCDG (DSG, 2016); e ESA (Mouratidis, 2014)
	Representam as altitudes da superfície topográfica, desconsiderando as alturas dos elementos geográficos existentes sobre ela, como cobertura vegetal e edificações	IBGE (2019)

Tabela 1 Quadro Comparativo de Definições de Modelos Digitais.

Dentre os produtos gerados pela interferometria de radar, Neeff *et al.* (2005) caracteriza a H_{int} como a diferença entre os modelos numéricos de elevação obtidos em bandas que representam modelos gerados no solo (MDT) e no dossel (MDS). Segundo Neeff *et al.* (2005), Gama (2007), Santoro & Cartus (2018) e Schlund *et al.* (2019) o valor da H_{int} tem relação com a característica física de altura total do indivíduo arbóreo, bem como o de biomassa florestal.

Na região amazônica, Neeff *et al.* (2005) trabalharam na Floresta Nacional (FLONA) do Tapajós utilizando dados polarimétricos e interferométricos de SAR das bandas X e P. Neste caso os autores analisaram a correlação entre a altura florestal e a H_{int} e entre a biomassa, a área basal, o retroespalhamento obtido pelas bandas polarimétricas e a H_{int} .

Para o cálculo da biomassa, Neeff *et al.* (2005) atingiram um coeficiente de determinação em torno de $r^2 = 0,84$ ao desenvolverem o modelo da Equação 1 onde a biomassa é dada em toneladas por hectare (t/ha), a H_{int} está em metros (m) e σ_{HH}^0 é o valor do coeficiente retroespalhamento na polarização HH em unidade de decibéis (dB).

$$\text{Biomassa} = 44,965 + 13,87H_{int} + 10,566 \sigma_{HH}^0 \quad (1)$$

Mais recentemente, Castro-Filho *et al.* (2013), após analisar diversas variáveis obtidas por dados SAR interferométricos e polarimétricos, conclui que a H_{int} foi a que obteve maior fator de correlação com a biomassa florestal aérea da região amazônica, no valor de $r = 0,70$.

2.4 Projeto Radiografia da Amazônia

No Brasil, entre os projetos que visam gerar imagens polarimétricas e interferométricas de SAR e que poderão ser utilizadas na estimativa de biomassa destaca-se o de Cartografia da Amazônia, mais especificamente o Subprojeto Cartografia Terrestre, também conhecido como “Radiografia da Amazônia”. Este projeto, coordenado pelo CENSIPAM (Centro Gestor e Operacional do Sistema de Proteção da Amazônia), visa recobrir uma área total de cerca de 1,1 milhão de km² da região amazônica, visando a elaboração de cartas na escala 1:50.000 pela DSG (2019). Além de realizar este mapeamento, o projeto visa também gerar dados necessários ao suporte de projetos de infraestrutura e exploração sustentável de recursos naturais da região.

No projeto será utilizada a tecnologia de SAR aerotransportado (sensor OrbiSAR), gerando diversos produtos, todos com resolução espacial de 5m: orto-imagens e imagens complexas X-HH e P-HH/HV/VV; MDS; e MDT. Além do grande volume de dados gerados, novos atributos

que melhor representam as características estruturais e de biomassa florestal poderão ser extraídos, como a H_{int} .

2.5 Técnicas de Busca de Solução

Diversas são as técnicas utilizadas para busca de solução, visando a definição dos valores de incógnitas em equações matemáticas. As técnicas de busca de solução podem ser divididas em paramétricas e não paramétricas, apresentando vantagens e limitações para cada caso.

As técnicas de busca de soluções paramétricas analisam os dados a partir de suas distribuições estatísticas. Uma das vantagens destas técnicas é a possibilidade de se utilizar as propriedades e técnicas estatísticas, como a de associar medidas de incerteza às estimativas.

No caso da solução paramétrica, existe grande destaque por parte das técnicas de regressão múltipla que buscam modelar uma variável, chamada de dependente, a partir de múltiplas outras variáveis, chamadas de independentes (Neter *et al.*, 1996). Esta abordagem é plenamente utilizada sobre dados de sensoriamento remoto, onde as variáveis dependentes comumente são bandas obtidas diretamente de sensores ou extraídas das mesmas. Dentre as técnicas paramétricas mais utilizadas, destaca-se o método dos mínimos quadrados, conforme Equação 2. Nele, é utilizado um sistema de equações a ser solucionada pela forma matricial

$$A^TAX=A^TY \quad (2)$$

onde as matrizes A e Y possuem valores conhecidos e a matriz X é a solução composta pelas incógnitas apresentadas nos modelos matemáticos.

Diferentemente, as técnicas de busca de solução não paramétricas não utilizam as características estatísticas dos dados de entrada, tornando-se independente de suas distribuições. No âmbito do sensoriamento remoto, estas técnicas costumam ser aplicadas sobre dados de SAR devido aos diferentes tipos de distribuição estatística que estes dados apresentam.

Um dos métodos de busca de solução não paramétricos é o do Gradiente Reduzido Generalizado (GRG) Não Linear apresentado por Carpentier & Abadie (1966), também conhecido como “método de solução”, ou “*solver*”, devido às diversas aplicações nas mais variadas áreas das ciências onde visa solucionar problemas matemáticos complexos.

Segundo Martínez & Santos (1995), o método GRG Não Linear tem a seguinte função:

- minimizar a função objetivo $z = f(\mathbf{X})$

- tendo a matriz de parâmetros que se deseja encontrar $\mathbf{X} \equiv [x_i]^T$
- e sujeito a função de restrições $h(\mathbf{X}) = 0, \beta \geq x \geq \alpha$.

O problema deve ser iniciado com um \mathbf{X}_k qualquer, preferencialmente próximo à solução. Através de um método iterativo, inicia-se a busca dos valores dos parâmetros utilizando a direção de busca identificada pelo gradiente reduzido $\nabla\varphi(\mathbf{X})$. Se o módulo do vetor gradiente reduzido $\nabla\varphi(\mathbf{X})$ for menor que a tolerância de convergência pré-definida, a variável \mathbf{X}_k é tida como ponto ótimo da função.

Outro método de busca de solução vastamente utilizado é o de Algoritmo Genético. Primeiramente utilizado por John Holland, em 1975, em seu livro *Adaptation in Natural and Artificial Systems*, o método foi apresentado como uma adaptação à Teoria da Evolução de Charles Darwin (Reeves, 2010).

O algoritmo genético clássico busca uma solução subótima para problemas matemáticos visando a maximização (ou minimização, dependendo do problema) de uma função objetivo. A busca inicia com um conjunto de soluções aleatórias chamado de “população”, onde os valores dos parâmetros matemáticos iniciais são os “cromossomos”. Na sequência, são realizadas iterações computacionais onde os valores dos cromossomos são ajustados, por meio de técnicas de “*crossover*” e de “*mutação*”, para que a população maximize a função objetivo.

No âmbito do sensoriamento remoto, algoritmos genéticos são usualmente utilizados para auxiliar na seleção de atributos, muitas vezes caracterizados por bandas espectrais, visando a classificação de tipos de uso do solo, como é o caso do trabalho de Singh & Singh (2017).

3 Metodologia

A área de estudo encontra-se inserida no município de São Gabriel da Cachoeira que é localizado às margens do Rio Negro, no noroeste do estado do Amazonas, conforme ilustrado na Figura 1. Conforme o Projeto RadamBrasil (1977) a maior parte da vegetação encontrada na área de estudo é composta por regiões fitoecológicas de contato florestal/formações edáficas (campinaranas). Estas regiões são caracterizadas de três formas:

- florestas densas, submontana e com o relevo dissecado. O Projeto RadamBrasil (1977) afirma que o volume médio de biomassa da área é de 107,4m³/ha;
- florestas densas, submontana e com o relevo ondulado; e
- florestas densas, terras baixas e relevo com presença de platôs.




Figura 1 Imagem de alta resolução do Google Earth (2019) da região amazônica da “cabeça do cachorro” com destaque para os blocos de processamento do Projeto “Radiografia da Amazônia”.

Os materiais utilizados são imagens obtidas por meio do Projeto “Radiografia da Amazônia” (DSG, 2019). As áreas de trabalho e as respectivas imagens utilizadas referem-se ao bloco compreendido entre as latitudes 0° e 1° sul e entre as longitudes 67° e 68° oeste, na localidade de São Gabriel da Cachoeira - AM. A Figura 1 apresenta imagens do sistema Google Earth (2019) referentes à região do extremo noroeste brasileiro, cuja fronteira com a Colômbia tem o formato semelhante à de uma “cabeça de cachorro” (em amarelo). Nesta figura observa-se, em cinza, o quadriculado referente aos blocos de processamento do Projeto “Radiografia da Amazônia”, de 1 (um) grau em longitude por 1 (um) grau em latitude, e em vermelho a sede municipal de São Gabriel da Cachoeira – AM.

Na Figura 2 (A,B,C e D) observa-se imagens da área de trabalho nas polarizações X-HH e P-HH/VV e imagem do Google Earth (2019). Apesar de não serem o foco do presente trabalho, por meio de imagens em diferentes polarizações é possível diferenciar importantes informações do terreno, como as diferentes classes de tipo e uso do solo.

A pesquisa foi estruturada de acordo com fluxograma apresentado na Figura 3, sendo que cada etapa será descrita nos itens a seguir.

3.1 Construção de Modelo Interferométrico Preliminar de Estimativa de Biomassa

Inicialmente foi construído um modelo preliminar de estimativa de biomassa, fundamental para possibilitar a posterior comparação com os demais modelos onde foram utilizadas H_{int} ajustadas, utilizando como variável independente, ou atributo, somente a H_{int} original. Detalhes sobre a construção deste modelo encontram-se descritos por Castro-Filho *et al.* (2013).

3.2 Definição de Modelo de Ajuste de Altura Interferométrica (H_{int})

A principal condição de contorno para o problema apresentado no presente trabalho é de que o valor da H_{int} nos pontos identificados como de solo exposto tenham o valor próximo a zero. Por outro lado, a hipótese a ser




Figura 2 Imagens da região de trabalho; A. X-HH; B. P-HH; C. P-VV; D. Imagem Google Earth (2019).

testada é de que seja possível o ajuste da H_{int} por meio da utilização de modelos matemáticos, visando melhoria no modelo de estimativa de biomassa florestal.

Os modelos matemáticos de ajuste utilizados serão os modelos polinomiais

$$aX^2 + bY^2 + cXY + dX + eY + f - H_{int} = 0 \quad (3)$$

e logarítmicos

$$alogX + blogY + c - dlogH_{int} = 0 \quad (4)$$

Nos modelos apresentados, os parâmetros de ajuste são representados pelas incógnitas a, b, c, d, e e f e as variáveis X e Y são valores das coordenadas no sistema UTM (Universal Transversa de Mercator) obtidos nas amostras de solo exposto.

3.3 Identificação e Coleta de Amostras de Solo Exposto

O processo de identificação de áreas de solo exposto foi foto-interpretativo, considerando a textura e as características do retroespalhamento nas imagens polarimétricas. Logo, as áreas de solo expostos foram




Figura 3 Fluxograma dos processos.

identificadas visualmente e os polígonos das áreas de interesse foram delimitados para compor as amostras da respectiva classe em estudo.

3.4 Análise e Seleção de Amostras

O processo de análise e seleção de amostras foi necessário pois foram observados que alguns pixels pertencentes às áreas de interesse coletadas representavam outros objetos distintos de solo exposto, como árvores isoladas, cujo valor da H_{int} deve ser diferente de zero. Logo, foi realizado um processo de identificação de *outliers* utilizando-se o parâmetro de 3 sigma (σ) e excluindo os valores destes pixels da média aritmética de cada uma das áreas de interesse.

3.5 Definição de Parâmetros de Ajuste por Método Paramétrico

O ajuste paramétrico sobre os modelos matemáticos apresentados no item 3.2 foi realizado por meio do método dos mínimos quadrados, conforme apresentado na Equação 2.

Neste caso, a matriz A foi composta pelos valores de coordenadas médias de cada área de interesse, a matriz Y serão os valores da H_{int} média de cada área de interesse e a matriz X será a solução composta pelas incógnitas dos modelos matemáticos.

3.6 Definição de Parâmetros de Ajuste por Método Não Paramétrico

A técnica de busca de solução não paramétrica utilizada foi um método de otimização que buscou por parâmetros que minimizassem o valor do erro médio quadrático, objetivando o valor da H_{int} média para cada área de interesse igual a zero. Neste caso utilizou-se tanto o método de GRG como o de algoritmo genético, ambos disponíveis no sistema Microsoft Excel.

3.7 Análise e Comparação dos Parâmetros de Ajuste

Foram analisados e comparados os parâmetros de ajuste obtidos pelos métodos paramétrico e não paramétrico, com o intuito de:

- compreender os valores de cada parâmetro, identificando as possíveis fontes de erro que levaram aos mesmos;
- identificar similaridades entre os parâmetros obtidos por diferentes métodos;
- analisar os erros médios quadráticos obtidos; e
- selecionar o(s) modelo(s) mais adequado(s) a serem aplicados na próxima etapa do processo, isto é, de ajuste da H_{int} .

3.8 Ajuste de Altura Interferométrica (H_{int})

Os modelos selecionados foram aplicados matematicamente à H_{int} dos pixels cujos valores de biomassa são conhecidos. A partir deste momento os valores passaram a ser chamados de H_{int} Ajustada.

3.9 Desenvolvimento de Modelo de Estimativa de Biomassa com H_{int} Ajustada

A partir dos valores ajustados foram desenvolvidos modelos de estimativa de biomassa, utilizando-se somente a técnica paramétrica de regressão estatística, visando obter solução para os valores das incógnitas. Optou-se somente pela solução paramétrica já que somente esta é capaz de gerar o coeficiente de correlação, indicador de qualidade que será utilizado no presente trabalho.

3.10 Análise Comparativa entre Modelos de Estimativa de Biomassa

A análise comparativa será realizada entre o modelo de estimativa de biomassa apresentado por Castro-Filho *et al.* (2013), conforme citado no subitem 3.1 deste trabalho,

e o modelo obtido pelo H_{int} Ajustado. Para tal, foram analisados ambos os valores dos coeficientes de correlação.

4 Resultados

4.1 Análise e Seleção de Amostras

Com base na identificação das áreas de solo exposto, foi realizada a coleta de 50 polígonos de áreas de interesse. Cada polígono foi composto, em média, por 338 pixels, totalizando uma amostra de 16.875 pixels de solo exposto.

A Tabela 2 apresenta, para cada um dos 50 polígonos, os valores médios iniciais de H_{int} , o valor do desvio padrão (σ), a quantidade total de pixels e a quantidade de pixels *outliers*, isto é, com módulos acima de 3σ . Ao analisar as amostras, observou-se que 36 dos 50 polígonos (72%) possuíam ao menos um pixel identificado como *outliers*. Os percentuais de *outliers* por polígono encontram-se destacados em vermelho na tabela.

Após a identificação dos pixels *outliers* e a respectiva exclusão, os valores médios de H_{int} para cada polígono foram recalculados. Os novos valores também se encontram na Tabela 2.

Apesar do percentual de polígonos que possuíam pixels identificados como *outliers* ter sido relativamente alto, a quantidade desses pixels totalizou 273, o que corresponde a somente 1,6% do total de pixels selecionados. Ao analisar as amostras selecionadas observou-se que alguns pixels isolados e internos a polígonos de solo exposto possuíam valores discrepantes, o que explica a ocorrência desses *outliers*. Embora não tenha havido trabalho de campo para comprovar *in loco* a existência de elementos referentes

Polígono	H_{int} Médio (m) Inicial	σ (m)	Qty Tot Pixels	Qty Outliers	% Outliers	H_{int} Médio (m) Recalculado
1	0,397	0,205	333	0	0%	0,397
2	0,315	0,114	474	7	1%	0,308
3	1,088	0,547	179	2	1%	1,069
4	0,422	0,274	320	10	3%	0,388
5	3,341	1,538	621	0	0%	3,341
6	0,430	0,489	434	14	3%	0,359
7	0,607	0,413	620	0	0%	0,607
8	0,766	0,353	98	1	1%	0,754
9	0,680	0,735	107	2	2%	0,627
10	0,290	0,117	259	0	0%	0,290
11	0,252	0,100	108	0	0%	0,252
12	0,454	0,336	110	3	3%	0,412
13	0,558	0,366	457	3	1%	0,547
14	0,575	0,428	304	5	2%	0,540
15	0,523	0,287	169	5	3%	0,494

Tabela 2 Análise de *Outliers*.

Proposta de Ajuste de Altura Interferométrica para Modelo de Estimativa de Biomassa
 Carlos Alberto Pires de Castro-Filho & Edilson de Souza Bias

Polígono	H _{int} Médio (m) Inicial	σ (m)	Qtd Tot Pixels	Qtd Outliers	% Outliers	H _{int} Médio (m) Recalculado
16	0,163	0,098	163	0	0%	0,163
17	0,913	1,685	265	13	5%	0,602
18	0,417	0,450	117	3	3%	0,356
19	2,872	0,944	61	0	0%	2,872
20	2,792	1,727	306	1	0%	2,775
21	1,074	0,762	251	3	1%	1,039
22	0,378	0,243	93	3	3%	0,350
23	0,371	0,358	286	10	3%	0,317
24	0,448	0,483	881	18	2%	0,406
25	0,477	0,464	422	10	2%	0,436
26	0,562	0,616	1462	32	2%	0,503
27	0,333	0,437	370	11	3%	0,270
28	2,322	1,413	865	15	2%	2,226
29	1,185	0,557	194	0	0%	1,185
30	0,745	0,598	230	4	2%	0,702
31	2,270	1,048	278	0	0%	2,270
32	8,375	1,135	132	0	0%	8,375
33	3,045	1,229	290	3	1%	3,004
34	6,843	2,261	232	0	0%	6,843
35	2,084	0,881	337	1	0%	2,076
36	0,717	0,842	124	2	2%	0,666
37	1,379	1,763	225	6	3%	1,202
38	0,884	0,639	150	1	1%	0,869
39	0,364	0,123	363	1	0%	0,362
40	0,386	0,073	257	1	0%	0,387
41	0,252	0,075	229	0	0%	0,252
42	0,297	0,043	556	9	2%	0,296
43	0,363	0,175	695	20	3%	0,344
44	0,709	0,819	1171	31	3%	0,634
45	1,206	1,616	274	7	3%	1,053
46	0,471	0,679	358	8	2%	0,383
47	0,943	0,747	182	3	2%	0,892
48	2,766	1,759	157	0	0%	2,766
49	1,602	1,563	156	0	0%	1,602
50	0,789	1,145	150	5	3%	0,655

Tabela 2 Cont.

aos pixels isolados, em alguns casos pôde-se supor que se tratavam de árvores isoladas.

A Tabela 3 apresenta os valores de E (coordenada leste UTM média), N (coordenada norte UTM média) e da H_{int} média para cada polígono de solo exposto identificado. Observa-se que alguns destes polígonos apresentam valores médios de H_{int} bem acima de zero, como é o caso dos polígonos 32 e 34, com valores destacados em vermelho.

4.2 Definição de Parâmetros de Ajuste por Método Paramétrico

Os valores das médias de X, Y e H_{int}, para cada polígono, foram aplicados sobre os modelos polinomiais e logarítmicos apresentados, respectivamente, nas Equações 3 e 4. Iniciou-se, portanto, a etapa de definição dos parâmetros de ajuste dos modelos.

Dentre os testes realizados envolvendo modelos paramétricos, o único modelo matemático que apresentou correlação significativa ($p < 0,01$) foi o logarítmico, conforme Equação 5.

$$\log H_{int} = - 58,4753 \log X + 342,15 \quad (5)$$

Durante o processo de definição de parâmetros, utilizando modelo paramétrico, observou-se que a matriz

A, descrita na Equação 2, não se mostrou inversível por possuir colunas, oriundas de variáveis, correlacionadas. Tal fato limitou os resultados possíveis no modelo paramétrico de definição de parâmetros.

4.3 Definição de Parâmetros de Ajuste por Método Não Paramétrico

Os resultados obtidos utilizando modelos não paramétricos para a definição de parâmetros de ajuste também foram limitados. Em diversos casos o algoritmo

Nº Polígono	E (m)	N (m)	H _{int} (m)	Nº Polígono	E (m)	N (m)	H _{int} (m)
1	721205,300	9983386,336	0,397	26	712316,143	9990773,685	0,503
2	721321,039	9983552,719	0,308	27	712524,095	9990789,387	0,270
3	722055,085	9983070,367	1,069	28	713433,471	9990653,224	2,226
4	721452,790	9983823,258	0,388	29	712827,010	9989834,098	1,185
5	720009,050	9984039,058	3,341	30	712693,960	9989846,327	0,702
6	719200,476	9984949,631	0,359	31	710890,162	9993316,259	2,270
7	716096,976	9986232,734	0,607	32	710981,818	9992679,735	8,375
8	716852,577	9984747,423	0,754	33	711530,732	9993308,031	3,004
9	715139,143	9985056,381	0,627	34	711364,698	9993100,151	6,843
10	715299,015	9984904,595	0,290	35	711947,366	9992965,655	2,076
11	714896,759	9985668,704	0,252	36	711596,434	9997336,598	0,666
12	714665,561	9985828,738	0,412	37	711481,438	9998210,868	1,202
13	712611,465	9985913,513	0,547	38	711646,678	9998572,718	0,869
14	712718,144	9985984,916	0,540	39	719636,395	9988305,967	0,362
15	712717,896	9985893,628	0,494	40	719783,008	9988354,727	0,387
16	712816,963	9986013,098	0,163	41	719868,581	9988564,410	0,252
17	713174,067	9985262,897	0,602	42	721165,932	9989448,876	0,296
18	712959,868	9985329,605	0,356	43	711923,400	9984351,370	0,344
19	712462,049	9985252,951	2,872	44	711307,092	9983909,504	0,634
20	711220,738	9987750,574	2,775	45	709222,247	9984210,318	1,053
21	710967,742	9986910,927	1,039	46	709461,771	9984239,714	0,383
22	710709,778	9986931,444	0,350	47	711958,603	9984199,749	0,892
23	712424,293	9988266,105	0,317	48	708350,000	9984405,955	2,766
24	712204,264	9989102,034	0,406	49	707629,103	9983892,436	1,602
25	712222,718	9989323,265	0,436	50	708219,207	9985361,345	0,655

Tabela 3 Valores de X (latitude média), Y (longitude média) e da H_{int} média para cada polígono de solo exposto identificado.

Modelo Polinomial (Equação 3): Precisão de Restrição: 1x10 ⁻¹³ ; Convergência: 1x10 ⁻¹⁴							
Incógnitas	a	b	c	d	e	f	Resíduo
Valores Iniciais	1x10 ⁻¹³	1x10 ⁻¹⁵	1x10 ⁻¹⁴	1x10 ⁻⁷	1x10 ⁻⁸	0	153,3275
1ª Iteração (Final)	-1,68x10 ²⁹	-8,16x10 ²⁹	5,12x10 ²⁹	5,94x10 ²⁹	8,60x10 ²⁹	-2,33x10 ²⁹	3,03x10⁸⁹

Tabela 4 Solução 1 Não Paramétrica.

Modelo Logarítmico (Equação 4): Precisão de Restrição: 0,01; - Convergência: 0,001					
Incógnitas	<i>a</i>	<i>b</i>	<i>c</i>	<i>d</i>	Resíduo
Valores Iniciais	0,2	0,15	-1	-2	75,233
1ª Iteração	0,1301	0,1030	-1,2984	-1,7803	24,245
2ª Iteração (Final)	0,1190	0,0955	-1,3462	-0,1804	0,2483

Tabela 5 Solução 2 Não Paramétrica.

Modelo Logarítmico (Equação 4): Precisão de Restrição: 0,001; Convergência: 0,0001					
Incógnitas	<i>a</i>	<i>b</i>	<i>c</i>	<i>d</i>	Resíduo
Valores Iniciais	0,2	0,15	-1	-2	75,233
1ª Iteração	0,1301	0,1030	-1,2984	-1,7804	24,245
2ª Iteração (Final)	0,1177	0,0946	-1,3515	-0,0002	3,22x10⁻⁶

Tabela 6 Solução 3 Não Paramétrica.

Modelo Logarítmico (Equação 4): Precisão de Restrição: 0,01; Convergência: 0,001; Início múltiplo com população de 10					
Incógnitas	<i>a</i>	<i>b</i>	<i>c</i>	<i>d</i>	Resíduo
Valores Iniciais	0,2	0,15	-1	-2	75,233
1ª Iteração	0,1301	0,1030	-1,2984	-1,7803	24,245
2ª Iteração	0,1190	0,0955	-1,3462	-0,1804	0,2483
3ª Iteração (Final)	-3,1540x10 ²⁹	-1,9523x10 ²⁹	-3,8432x10 ²⁹	6,4128x10 ²⁹	6,1893x10⁶²

Tabela 7 Solução 4 Não Paramétrica.

de busca não convergiu para uma solução com função objetivo próxima a zero, como são os casos apresentados nas Tabelas 4 e 7.

A busca de solução por algoritmo genético não obteve qualquer resultado satisfatório por não ter convergido para uma solução, logo não serão apresentados no presente trabalho. Os parâmetros utilizados foram os seguintes: população de tamanho 500 e 1000; taxa de mutação de 2% e 5%; e *crossover* por elitismo de 20% e 30%.

Já, o ajuste por GRG convergiu para algumas soluções, tendo como parâmetros de parada de busca do algoritmo o tempo máximo de 100 segundos e o número máximo de 1000 iterações.

A seguir encontram-se alguns exemplos de soluções obtidas por meio do sistema Microsoft Excel Solver utilizando modelos matemáticos polinomiais (Tabela 4) e logarítmicos (Tabelas 5, 6 e 7). Além dos modelos matemáticos, nas tabelas também se encontram os parâmetros de precisão de restrição e convergência aplicados ao algoritmo de busca do GRG.

Das soluções obtidas, somente a Solução 2 Não Paramétrica (Tabela 5) e a Solução 3 Não Paramétrica (Tabela 6) convergiram, respectivamente, para resíduos de 0,2483m e 3,22 x 10⁻⁶m, ambos na segunda iteração. A Solução 1 Não Paramétrica (Tabela 4) e a Solução 4 Não Paramétrica (Tabela 7) apresentaram resultados

insatisfatórios, divergindo para valores de resíduos de 3,03 x 10⁸⁹m e 6,1893 x 10⁶²m. Em função destes resultados obtidos nos testes para o método não paramétrico, no presente trabalho será dada continuidade somente aos modelos não paramétricos das Soluções 2 e 3.

Em função dos parâmetros obtidos na Tabela 5, a equação de ajuste para a Solução 2 Não Paramétrica é:

$$0,1190 \log X + 0,0955 \log Y - 1,3462 + 0,1804 \log H_{\text{int}} = 0$$

ou

$$\log H_{\text{int}} = - 0,6596 \log X - 0,5294 \log Y + 7,4623 \quad (6)$$

Da mesma forma, a equação de ajuste para a Solução 3 Não Paramétrica, conforme parâmetros da Tabela 6, é a seguinte:

$$0,1177 \log X + 0,0946 \log Y - 1,3515 + 0,0002 \log H_{\text{int}} = 0$$

ou

$$\log H_{\text{int}} = - 588,5 \log X - 473,0 \log Y + 6757,5 \quad (7)$$

4.4 Análise e Comparação dos Parâmetros de Ajuste

Ao analisar as soluções de ajuste apresentadas nas Equações 5, 6 e 7, observa-se que, tanto para o ajuste

paramétrico como para o não paramétrico, somente o modelo matemático logarítmico apresentou resultados significativos. Da mesma forma, em todos os casos os parâmetros que acompanham as variáveis independentes X e Y possuem sinal negativo, seguido de um valor positivo de translação no eixo Z.

O modelo paramétrico da Equação 5 independe da variável independente Y, a qual corresponde à variação geográfica na latitude. Por ser dependente somente de X, entende-se que o ajuste a ser realizado no valor de H_{int} varia somente com a longitude. Neste caso, observa-se que a imagem em trabalho possui um efeito de “rampa” em somente uma direção.

Por outro lado, os modelos não paramétricos das Equações 6 e 7 apresentaram dependência com ambas as variáveis X e Y. Destaca-se o fato de que em ambos os casos os parâmetros obtidos estão proporcionais, isto é, na Equação 6 ambos são decimais, quanto na Equação 7 ambos são centenas.

Com relação aos resíduos obtidos, a Equação 7, referente ao processamento da Tabela 4, foi a que apresentou o melhor resultado, apresentando um modelo de ajuste para H_{int} que tornou nulo o valor para áreas de solo exposto.

4.5 Ajuste de H_{int} e desenvolvimento de Modelo de Estimativa de Biomassa com H_{int} Ajustada

Os modelos de ajuste das Equações 5, 6 e 7 foram aplicados na H_{int} original obtendo então três novos valores de H_{int} ajustada, respectivamente, H_{intAj1} , H_{intAj2} e H_{intAj3} . Cada uma dessas novas bandas foi então utilizada como atributo em um modelo de estimativa de biomassa, obtendo os seguintes resultados de coeficiente de correlação:

$$\begin{aligned} H_{intAj1} &\rightarrow r = 0,5290; \\ H_{intAj2} &\rightarrow r = 0,7512; \\ H_{intAj3} &\rightarrow r = 0,7564. \end{aligned}$$

Observa-se que, dos resultados obtidos, somente os coeficientes de correlação envolvendo as H_{intAj2} e H_{intAj3} foram significativamente positivos, isto é, como valores acima ou próximos de 0,75.

4.6 Análise Comparativa entre Modelos de Estimativa de Biomassa

A Figura 4 apresenta o modelo preliminar de estimativa de biomassa desenvolvido com a H_{int} original (Castro-Filho *et al.*, 2013), enquanto as Figuras 5(A) e 5(B) apresentam os modelos envolvendo os atributos ajustados de H_{intAj2} e H_{intAj3} . A diferença entre o coeficiente de correlação do modelo inicial ($r = 0,7518$) e dos modelos ajustados ($r = 0,7512$ e $r = 0,7564$) não foi significativa.




Figura 4 Modelo Preliminar.

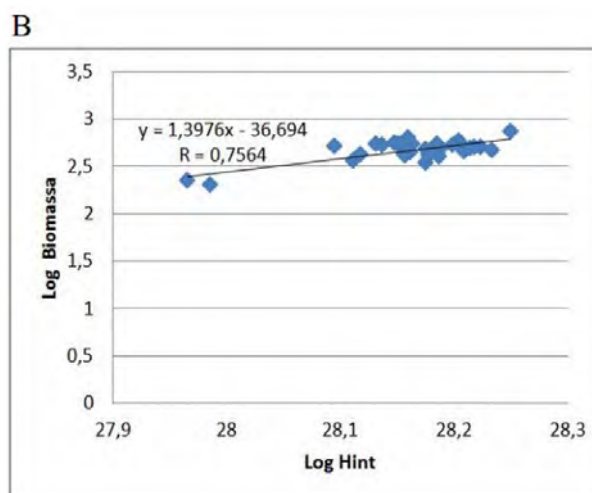



Figura 5 Modelos Ajustados; A. Modelo envolvendo a H_{intAj2} ; B. Modelo envolvendo a H_{intAj3} .

Os parâmetros dos modelos de estimativa de biomassa apresentados nas Figuras 4 e 5(A) se apresentaram equivalentes, o que resultou em modelos com gráficos semelhantes. Por outro lado, a Figura 5(B) apresenta um modelo com valores mais dispersos no eixo das abscissas, o que contribuiu para um valor de coeficiente de correlação ligeiramente superior.

5 Conclusão

O presente trabalho teve por finalidade aumentar a precisão altimétrica dos dados obtidos pelo sensor de SAR e o conseqüente aumento na quantidade de aplicações, incluindo as na área de engenharia de infraestruturas, de monitoramento ambiental e de estimativa de biomassa florestal.

De forma inovadora, o trabalho contribuiu para esta finalidade por meio:

- da apresentação da premissa de que as regiões da classe de solo exposto devem ter altura interferométrica igual a zero; e
- do desenvolvimento de uma metodologia composta por diversos testes de modelagem de ajuste paramétrico e não paramétrico, baseados em modelos matemáticos polinomiais e logarítmicos. No âmbito da metodologia, foram aplicados os métodos de busca de Gradiente Reduzido Generalizado e de algoritmo genético, com diferentes parâmetros, utilizando o sistema computacional comercial Microsoft Excel Solver.

Os testes não obtiveram os resultados esperados, havendo poucos casos onde o algoritmo convergiu para o objetivo de anular o valor da altura interferométrica em regiões de solo exposto. Apesar das análises efetuadas sobre os resultados, não foi possível identificar o motivo da falta de convergência visto que o sistema comercial não é aberto e não permite a análise do código computacional implementado, o que o torna limitado para este tipo de aplicação.

Visando superar esta limitação, novos estudos serão realizados incluindo o uso de outros sistemas ou métodos não paramétricos de busca de solução, disponíveis comercialmente ou desenvolvidos para atender especificamente este objetivo. Dentre esses métodos, sugere-se o de “subida de colina” e o de “colônia de formigas”.

Dentre os testes que obtiveram resultados convergentes, não foi possível melhorar significativamente a estimativa de biomassa florestal por meio dos modelos matemáticos aplicados. Logo, a hipótese de que é possível

o ajuste da altura interferométrica utilizando áreas de solo exposto como condição de contorno também não foi comprovada.

Analisando as limitações dos dados utilizados no presente trabalho, foram identificados três fatores que poderão vir a contribuir para novas pesquisas na área em foco.

O primeiro fator se refere à quantidade de parcelas inventariadas de manejo florestal utilizadas como amostras. Uma quantidade superior de parcelas possibilitaria uma representação amostral mais fidedigna e uma maior variação de valores de biomassa na região de estudo, com o conseqüente aumento de aderência da reta de regressão estatística e do coeficiente de correlação.

O segundo fator está relacionado à dificuldade em observar regiões de solo exposto próximas a parcelas inventariadas de biomassa florestal. Neste caso, sugere-se o uso de dados de inventários florestais que sejam mais próximos de regiões antropizadas e fartas em áreas de solo exposto.

O terceiro fator identificado é a disponibilidade de pontos de controle sobre a área em estudo. Por meio de pontos de controle medidos *in loco* e distribuídos em regiões próximas aos inventários florestais, será possível analisar minuciosamente as variações geométricas dos modelos digitais de SAR submetidos aos modelos matemáticos de ajuste desenvolvidos.

6 Referências

- Araújo, T.M.; Higuchi, N. & Junior, J.A.C. 1999. Comparison of formula for biomass content determination in a tropical rain forest in the state of Pará, Brazil. *Forest Ecology and Management*, 117: 43-52.
- Burrough, P.A. 1986. *Principles of Geographical Information Systems for land resource assessment*. London, Oxford University Press, 193p.
- Felgueiras, C.A. 2004. Modelagem Numérica de Terreno. In: CÂMARA, G.; DAVIS, C. & MONTEIRO, A.M.V. (ed.). *Introdução à Ciência da Geoinformação*. Instituto de Pesquisas Espaciais (INPE). Disponível em: <<http://www.dpi.inpe.br/gilberto/livro/introd/cap7-mnt.pdf>>. Acesso em: 4 dez 2019.
- Carpentier, J. & Abadie, J. 1966. Généralisation de la Méthode du Gradient Réduit de Wolfe au cas des Contraintes Non Lineaires. In: IV INTERNATIONAL CONFERENCE ON OPERATIONAL RESEARCH. Nova York, 1966.
- Castro-Filho, C.A.P.; Freitas, C.C.; Sant’anna, S.J.S.; Lima, A.J.N. & Higuchi, N. 2013. Relating Amazon Forest Biomass to PolInSAR Extracted Features. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), Melbourne, 2013. Resumos expandidos, Melbourne, p. 2111-2114.

- Debastiani, A.B.; Moura, M.M.; Rex, F.D.; Sanquetta, C.R.; Corte, A.P.D. & Pinto N. 2019. Regressões Robusta e Linear para Estimativa de Biomassa via Imagem Sentinel em uma Floresta Tropical. *BIOFLIX Scientific Journal*, 4: 81-87.
- DSG. 2016. Diretoria de Serviço Geográfico. Especificação Técnica para Produtos de Conjunto de Dados Geoespaciais (ET-PCDG). Disponível em: <<http://www.geoportal.eb.mil.br/portal/inde2>>. Acesso em: 4 dez. 2019.
- DSG. 2019. Diretoria de Serviço Geográfico. Radiografia da Amazônia. Disponível em: <<http://www.geoportal.eb.mil.br/portal/index.php/projetos/147-projeto-cartografia-da-amazonia>>. Acesso em: 4 dez. 2019.
- Gama, F.F. 2007. *Estudo da interferometria e polarimetria SAR em povoamentos florestais de eucalyptus SP*. Programa de Pós-graduação em Sensoriamento Remoto. Instituto Nacional de Pesquisas Espaciais, Tese de Doutorado, 243 p.
- Google Earth. 2019. Disponível em: <<http://www.google.com.br/intl/pt-BR/earth/>>. Acesso em: 22 fev. 2019.
- IBGE. 2019. Instituto Brasileiro de Geografia e Estatística. Manuais Técnicos em Geociências, N° 14 – Acesso e Uso de Dados Geoespaciais. Disponível em: <<https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=2101675>>. Acesso em: 4 dez. 2019.
- JAXA. 2019. Japanese Space Agency. ALOS Global Digital Surface Model “ALOS World 3D - 30m (AW3D30)”. Disponível em: <<https://www.eorc.jaxa.jp/ALOS/en/aw3d30/index.htm>>. Acesso em 26 de dez. 2019.
- Martínez, J.M. & Santos, S.A. 1995. *Métodos computacionais de otimização*. Campinas, Departamento de Matemática Aplicada IMECC-UNICAMP, 262p.
- Mouratidis A. 2014. Geographical Information Systems. In: ESA SAR COURSE, Malta, 2014. Disponível em: <https://earth.esa.int/documents/10174/1743079/02_Antonios_Mouratidis_GIS_overview.pdf>. Acessado em: 26 dez. 2019.
- Neeff, T.; Dutra, L.V.; Santos, J.R.; Freitas, C.C. & Araújo, L.S. 2005. Tropical forest biomass measurement by interferometric height modeling and P-band radar backscatter. *Forest Science*, 51(6): 585–594.
- Neter, J.; Kutner, M.H.; Nachtsheim, C.J. & Wasserman, W. 1996. *Applied Linear Statistical Models*. Boston, McGraw-Hill, 1408 p.
- Oliveira, M.V.N.D & Locks C.J. 2019. Potencial de uso de SAR aerotransportado para modelagem do terreno e da biomassa acima do solo em região de floresta tropical. In: XIX SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, Santos, 2019. Resumo expandido, Santos, INPE, p. 1855-1858. Disponível em: <<https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1113331/potencial-de-uso-de-sar-aerotransportado-para-modelagem-do-terreno-e-da-biomassa-acima-do-solo-em-regiao-de-floresta-tropical>>. Acesso em: 26 dez. 2019.
- Pope, K.O.; Benayas-Rey, J.M. & Paris, J.F. 1994. Radar remote sensing of forest and wetland ecosystems in the Central American tropics. *Remote Sensing of Environment*, 48(2): 205-219.
- Projeto RadamBrasil. 1977. *Folha SA.19 Içá/Amazonas: geologia, geomorfologia, pedologia, vegetação e uso potencial da terra*. Rio de Janeiro, Departamento Nacional da Produção Mineral, 452 p.
- Reeves, C. 2010. Genetic Algorithms. In: Reeves, C. (ed.). *Handbook of Metaheuristics*. Coventry University, p. 55-82. Disponível em: <https://www.researchgate.net/publication/226462334_Genetic_Algorithms>. Acesso em: 06 dez. 2019.
- Saatchi, S.; Halligan, K.; Despain, D.G. & Crabtree, R.L. 2007. Estimation of forest fuel load from radar remote sensing. *IEEE Transactions on Geoscience and Remote Sensing*, 45(6): 1726 – 1740.
- Santos, J.R.; Freitas, C.C.; Araújo, L.S.; Dutra, L.V.; Mura, J.C.; Gama, F.F.; Soler, L.S. & Sant’Anna, S.J.S. 2003. Airborne P-band SAR applied to the aboveground biomass studies in the Brazilian tropical rainforest. *Remote Sensing of Environment*, ELSEVIER, 87: 482-493.
- Santoro M. & Cartus O. 2018. Research Pathways of Forest Above-Ground Biomass Estimation Based on SAR Backscatter and Interferometric SAR Observations. *Remote Sensing*, 10(4): 1-23. Disponível em: <<https://www.mdpi.com/2072-4292/10/4/608>>. Acesso em: 06 dez. 2019.
- Schlund, M.; Erasmi, S. & Scipal, K. 2019. Comparison of Aboveground Biomass Estimation From InSAR and LiDAR Canopy Height Models in Tropical Forests. *IEEE Geoscience and Remote Sensing Letters*, 17(3): 367-371.
- Singh, A. & Singh, K.K. 2017. Satellite image classification using Genetic Algorithm trained radial basis function neural network, application to the detection of flooded areas. *Journal of Visual Communication and Image Representation*, 42: 173–182.
- Zhang, H.; Huang M.; Qing X.; Li G. & Tian C. 2017. Bibliometric Analysis of Global Remote Sensing Research during 2010–2015. *International Journal of Geo-information*, 16(3): 87-102.