

GETULIO FONSECA DOMINGUES

**ESTIMAÇÃO DE BIOMASSA AÉREA E VOLUME EM POVOAMENTOS DE
EUCALIPTOS ATRAVÉS DE IMAGENS DO SATÉLITE ALOS**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Magister Scientiae*.

**VIÇOSA
MINAS GERAIS – BRASIL
2015**

T

D671e
2015

Domingues, Getulio Fonseca, 1988-

Estimação de biomassa aérea e volume em povoamentos de eucaliptos através de imagens do satélite ALOS / Getulio Fonseca Domingues. – Viçosa, MG, 2015.

ix, 55f. : il. (algumas color.) ; 29 cm.

Inclui apêndice.

Orientador: Vicente Paulo Soares.

Dissertação (mestrado) - Universidade Federal de Viçosa.

Referências bibliográficas: f.49-54.

1. Eucalipto. 2. Biomassa florestal. 3. Floresta - Medição.
4. Redes neurais (Computação). 5. Satélite artificiais em sensoriamento remoto. I. Universidade Federal de Viçosa. Departamento de Engenharia Florestal. Programa de Pós-graduação em Ciência Florestal. II. Título.

CDD 22. ed. 634.973766

GETULIO FONSECA DOMINGUES

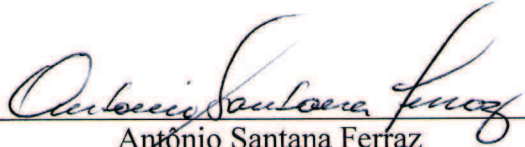
**ESTIMAÇÃO DE BIOMASSA AÉREA E VOLUME EM POVOAMENTOS DE
EUCALIPTOS ATRAVÉS DE IMAGENS DO SATÉLITE ALOS**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Florestal, para obtenção do título de *Magister Scientiae*.

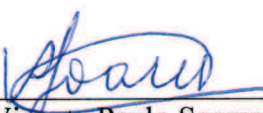
APROVADA: 12 de fevereiro de 2015.



Helio Garcia Leite



Antonio Santana Ferraz



Vicente Paulo Soares
(Orientador)

AGRADECIMENTOS

A Deus, por me permitir estar aqui neste momento e me dar forças para seguir em frente.

À minha família, pelo amor incondicional e apoio nesta e em todas as etapas da minha vida.

Ao meu orientador, Prof. Vicente Paulo Soares, pela orientação, incentivo e colaboração para realizar este trabalho.

Aos professores Carlos Antonio Álvares Soares Ribeiro e Helio Garcia Leite pelo apoio e por serem sempre solícitos, desde a graduação até o mestrado.

Aos amigos de Viçosa, em especial a galera da republica e a turma do laboratório SIGMA no DEF.

À minha namorada Melissa, pela paciência e por estar sempre disposta a me ajudar.

À Universidade Federal de Viçosa, por intermédio do Departamento de Engenharia Florestal, pela oportunidade de realizar o curso.

Ao CNPq, Conselho Nacional de Desenvolvimento Científico e Tecnológico, pela concessão da bolsa de mestrado.

Agradeço

SUMÁRIO

	Pág.
LISTA DE FIGURAS	Iv
LISTA DE TABELAS	Vii
RESUMO	Viii
ABSTRACT	Ix
1 INTRODUÇÃO	1
2 REVISÃO DE LITERATURA	
2.1 Comportamento Espectral dos Alvos	3
2.2 Sensores óticos	4
2.3 Sensoriamento Remoto por RADAR	6
2.4 O satélite ALOS	8
2.5 Redes Neurais Artificiais (RNA)	12
3 MATERIAIS E MÉTODOS	
3.1 Área de estudo	16
3.2 Imagens e softwares	16
3.3 Inventário florestal	17
3.4 Seleção das parcelas e extração dos valores numéricos dos pixels	18
3.5 Estimativas do volume e da biomassa a partir das imagens AVNIR-2 e PALSAR	18
4 RESULTADOS E DISCUSSÃO	22
4.1 Treinamento de 200.000 redes neurais MLP para estimar a variável volume	22
4.2 Treinamento de 200.000 redes neurais MLP para estimar a variável biomassa	26
4.3 Estimativas de volume e biomassa com 5.000 redes neurais	30
4.3.1 Estimativas de volume com 5.000 redes neurais	30
4.3.2 Estimativas de biomassa com 5.000 redes neurais	33
4.4 Estimativas de volume e biomassa variando o número de parcelas para treinamento da rede	36
5 CONCLUSÃO	48
6 REFERÊNCIAS BIBLIOGRÁFICAS	49
7 APÊNDICE A	55

LISTA DE FIGURAS

		Pág.
Figura	1- Assinatura espectral da vegetação em diferentes condições de stress.	3
Figura	2- Satélite ALOS	9
Figura	3- Estrutura de uma rede neural artificial.	13
Figura	4- Localização da área de estudo nos municípios de Belo oriente, Santana do Paraíso, Ipaba e Caratinga-MG.	17
Figura	5- Máscara para extração do valor numérico da parcela.	18
Figura	6- Parada do treinamento utilizando uma amostra para teste.	22
Figura	7- Gráficos dos comportamentos dos erros de validação e treinamento por números de neurônios na camada oculta para estimar volume. Função tangente hiperbólica na camada oculta e de saída: a) Identidade; b) Logística; c) Tangente hiperbólica; d) Exponencial.	24
Figura	8- Gráficos dos comportamentos dos erros de validação e treinamento por números de neurônios na camada oculta para estimar volume. Função logística na camada oculta e de saída: a) Identidade; b) Logística; c) Tangente hiperbólica; d) Exponencial.	25
Figura	9- Gráficos dos comportamentos dos erros de validação e treinamento por números de neurônios na camada oculta para estimar volume. Função exponencial na camada oculta e de saída: a) Identidade; b) Logística; c) Tangente hiperbólica; d) Exponencial.	26
Figura	10- Gráficos dos comportamentos dos erros de validação e treinamento por números de neurônios na camada oculta para estimar biomassa. Função tangente hiperbólica na camada oculta e de saída: a) Identidade; b) Logística; c) Tangente hiperbólica; d) Exponencial.	27

Figura	11-	Gráficos dos comportamentos dos erros de validação e treinamento por números de neurônios na camada oculta para estimar biomassa. Função logística na camada oculta e de saída: a) Identidade; b) Logística; c) Tangente hiperbólica; d) Exponencial.	28
Figura	12-	Gráficos dos comportamentos dos erros de validação e treinamento por números de neurônios na camada oculta para estimar biomassa. Função exponencial na camada oculta e de saída: a) Identidade; b) Logística; c) Tangente hiperbólica; d) Exponencial.	29
Figura	13-	Gráficos de resíduos utilizando o sensor AVNIR-2 para estimar volume.	31
Figura	14-	Gráficos de resíduos utilizando o sensor PALSAR para estimar volume.	32
Figura	15-	Gráficos de resíduos utilizando os sensores AVNIR-2 e PALSAR para estimar volume.	33
Figura	16-	Gráficos de resíduos utilizando o sensor AVNIR-2 para estimar biomassa.	34
Figura	17-	Gráficos de resíduos utilizando o sensor PALSAR para estimar biomassa.	35
Figura	18-	Gráficos de resíduos utilizando os sensores AVNIR-2 e PALSAR para estimar biomassa.	36
Figura	19-	Gráficos de resíduos do volume utilizando 84 parcelas para treinamento.	37
Figura	20-	Gráficos de resíduos do volume utilizando 62 parcelas para treinamento.	38
Figura	21-	Gráficos de resíduos do volume utilizando 42 parcelas para treinamento.	39
Figura	22-	Gráficos de resíduos do volume utilizando 22 parcelas para treinamento.	40
Figura	23-	Gráficos de resíduos da biomassa utilizando 84 parcelas para treinamento.	41
Figura	24-	Gráficos de resíduos da biomassa utilizando 62 parcelas para	42

		treinamento.	
Figura	25-	Gráficos de resíduos da biomassa utilizando 42 parcelas para treinamento.	43
Figura	26-	Gráficos de resíduos da biomassa utilizando 22 parcelas para treinamento.	44

LISTA DE TABELAS

		Pág.
Tabela	1- Características do sensor AVNIR-2	10
Tabela	2- Características do sensor PALSAR	11
Tabela	3- Características do sensor PRISM	12
Tabela	4- Variáveis AVNIR-2 utilizadas nas análises estatísticas	19
Tabela	5- Variáveis do sensor PALSAR utilizadas nas análises estatísticas	19
Tabela	6- Número máximo de neurônios para cada arquitetura de rede neural nas estimativas de volume	30
Tabela	7- Número máximo de neurônios para cada arquitetura de rede neural nas estimativas de biomassa	30
Tabela	8- Redes neurais selecionadas para estimar o volume e a biomassa	45
Tabela	9- Análise global de sensibilidade	46
Tabela	10- Parcelas de estudo	55

RESUMO

DOMINGUES, Getulio Fonseca, M.Sc., Universidade Federal de Viçosa, fevereiro de 2015. **Estimação de biomassa aérea e volume em povoamentos de eucaliptos através de imagens do satélite ALOS.** Orientador: Vicente Paulo Soares. Coorientador: José Marinaldo Gleriani.

As estimativas de biomassa aérea e volume, tanto de florestas inequiâneas quanto de equiâneas são necessárias para estudos de sequestro de carbono, avaliação da regeneração natural de matas ciliares, estudos relacionados à conservação de recursos naturais, quantificação da ciclagem de nutrientes, e planejamento energético em regiões onde a biomassa florestal é utilizada como combustível primário para geração de energia. Utilizando dados dos sensores AVNIR-2 e PALSAR do satélite ALOS foram estimadas biomassa e volume empregando redes neurais artificiais para uma área de reflorestamento com eucaliptos, localizada nos municípios de Ipaba e Belo Oriente no estado de Minas Gerais. As estimativas de volume apresentaram coeficiente de correlação de 0,99, com os correspondentes volumes observados (inventário florestal), raiz quadrada do erro quadrático (RQEM) em porcentagem de 0,3% e erros com amplitude entre -1 a 1%. As estimativas de biomassa apresentaram coeficiente de correlação de 0,97, com os valores de biomassa observados no método destrutivo de quantificação, RQEM% de 2,87 e erros entre -8 a 5%. A eficiência das redes neurais artificiais para estimação da produção (em m³ e t. de biomassa) foi comprovada.

ABSTRACT

DOMINGUES, Getulio Fonseca, M.Sc., Universidade Federal de Viçosa, February, 2015. **Biomass and wood volume estimation in stands of eucalyptus using images from ALOS satellite.** Advisor: Vicente Paulo Soares. Co-Advisor: José Marinaldo Gleriani

The estimation of biomass and volume, both of uneven-aged and even-aged forest, are necessary for studies related to carbon sequestration, evaluation of riparian zones regeneration, natural resources conservation, nutrient cycling quantification and energy planning where forest biomass is used as fuel for power generation. In this study, data obtained from AVNIR-2 and PALSAR sensors within ALOS satellite were used to estimate biomass and volume in a Eucalyptus forest plantation, located in the municipalities of Ipaba and Belo Oriente, State of Minas Gerais, Brazil, through artificial neural network analysis. The results showed correlation coefficient of 0.99 between the estimated and observed volume (forest inventory), Root Mean Squared Error (RMSE) of 0.3% and range errors between -1 and +1%. Results also showed higher correlation coefficient of 0.97 between the estimated and observed biomass (quantified by the destructive method), RMSE of 2.87% and range errors between -8 and +5%. The neural network produced accurate results even with few data plots.

1. INTRODUÇÃO

O sensoriamento remoto tem sido bastante utilizado para a modelagem e o manejo de ecossistemas (Mas et al., 2004; Balzter, 2001), mapeamento da riqueza de espécies e composição florestal (Foody & Cutler, 2006) e para estimativas de parâmetros florestais de matas nativas (Barbosa et al., 2014; Soenen et al., 2010; Sarker & Nichol, 2011; Lu, 2005; Reese et al., 2002;) e de florestas plantadas como as dos gêneros *Pinus* e *Eucalyptus* (Viana et al., 2012; Cortés et al., 2014). Isto tem ocorrido devido à disponibilidade de imagens de alta resolução, provenientes de sensores remotos passivos e ativos, e os avanços nas técnicas de processamento digital destas imagens.

A utilização dos sensores remotos ativos, Lidar e radares de abertura sintética, para estimar parâmetros biofísicos da cobertura florestal (altura, diâmetro, fustes, volume e biomassa) aumentaram significativamente visto à interação do sinal de microondas do sensor radar com a vegetação em determinadas faixas de frequência e polarização, bem como às melhorias tecnológicas oferecidas, como polarimetria, interferometria e uma melhor qualidade/estabilidade da radiometria do radar (Carreiras et al., 2012; Santos et al., 2012; Gama et al., 2010; Balzter, 2001).

Mais ainda, estudos demonstram que combinar informações de sensores remotos e dados obtidos em campo aumenta a acurácia das estimativas de parâmetros florestais (Baghdadi et al., 2014; Cortés et al., 2014; Zolkos et al., 2013; Englhart et al., 2011). Oliveira (2011) utilizou dados provenientes dos sensores AVNIR-2, PRISM e PALSAR a bordo do satélite ALOS (Advanced Land Observing Satellite) para estimar o volume e a biomassa aérea de plantações de eucalipto através do método estatístico de análise de regressão. Prosseguindo na linha de estudos de Oliveira (2011), foram utilizadas no presente trabalho as refletâncias do sensor AVNIR-2 e os retroespalhamentos do sensor PALSAR, para estimar o volume e a biomassa aérea das plantações de eucalipto, empregando-se a técnica de Redes Neurais Artificiais.

O satélite ALOS está equipado com três instrumentos sensores: 1) o Panchromatic Remote-Sensing Instrument for Stereo Mapping (PRISM), que é o sensor com uma banda pancromática; 2) o Advanced Visible and Near Infrared Radiometer

type2 (AVNIR-2), sensor multispectral, que possui 4 bandas espectrais abrangendo a região espectral do visível e infra-vermelho próximo e 3) Phased Array type L-band Synthetic Aperture Radar (PALSAR) que é o sensor radar, para observação da Terra dia e noite e em todas as condições climáticas (JAXA, 2012).

A rede neural artificial é um modelo computacional de inteligência artificial que simula o funcionamento de uma rede de neurônios biológicos. São utilizadas para análises não lineares complexas e não é necessária nenhuma suposição sobre os dados utilizados, ao contrario dos métodos estatísticos paramétricos, como análise de regressão, onde se pressupõem homogeneidade das variáveis, normalidade dos erros e ausência de correlação entre as variáveis independentes (Foody et. al, 2001). Em alguns estudos, redes neurais foram utilizadas para estimar parâmetros florestais a partir de dados de sensoriamento remoto, onde demonstraram o potencial de utilização desta técnica a partir de dados multivariados (Mas et al., 2004; Frate & Solimini, 2004; Muukkonen & Heiskanen, 2005; Blackard & Dean, 1999).

Comparando os parâmetros florestais estimados, obtidos pelos ajustes realizados entre redes neurais e análises de regressão, Ozçelik et al., (2013), Castaño-Santamaría et al., (2013), Diamantopoulou (2005) concluíram que as redes neurais tem potencial para superar diversos problemas em dados florestais, como as relações não lineares, distribuições não normais, outliers e ruídos, além de despontar como uma promissora alternativa à modelos de regressão em modelagem florestal. As redes são treinadas para encontrar uma relação entre as variáveis. Este treinamento é feito por algoritmos que ajustam os pesos das conexões entre neurônios a fim de minimizar a função do erro, muitas vezes definida como a soma dos quadrados dos resíduos.

Diante do exposto, este trabalho teve como objetivo estimar os parâmetros biofísicos volume e biomassa aérea de plantações de eucaliptos com dados dos sensores AVNIR-2 e PALSAR do satélite ALOS, utilizando a técnica de redes neurais artificiais.

2. REVISÃO DE LITERATURA

2.1. Comportamento Espectral dos Alvos

A interação da radiação eletromagnética com feições da superfície terrestre ocorre de três maneiras fundamentais: absorção, transmissão e reflexão. Dentre elas, o fenômeno da reflexão é o mais utilizado no sensoriamento remoto, devido à maior facilidade de medição desse fenômeno. Nos dias de hoje, com o avanço tecnológico, os sensores podem captar a radiação eletromagnética em diferentes comprimentos de onda. Com isso, é possível obter a assinatura espectral das feições de interesse, que devido às suas características intrínsecas, podem ser diferenciadas das demais feições na imagem (Lillesand et al.2007) (Figura 1).




Figura 1 - Assinatura espectral da vegetação em diferentes condições de stress (Filho et al., 2008).

As principais características que influenciam na resposta espectral dos vegetais são sua morfologia e suas características fisiológicas como a composição, a idade e o conteúdo hídrico. A radiação capturada pelo sensor é convertida em valores digitais, que são atribuídos aos pixels que compõem a imagem original da cena, representando a radiação média refletida ou emitida pelos elementos existentes na área definida pelo pixel. Estes valores são dependentes de diversos fatores, como a data do imageamento, das condições naturais no momento da aquisição, do relevo da área, da banda espectral, da posição do sensor, além das características das feições na imagem (Ferraz, 2012).

2.2. Sensores óticos

O sensor ótico para imageamento terrestre, assim definido pelo fato de ser sensível aos mesmos comprimentos de ondas que o olho humano, teve origem juntamente com o começo da fotografia. As primeiras imagens aéreas da superfície terrestre foram tomadas através de balões em 1858. O próximo passo foi em 1909, quando Wilbur Weight pilotou uma aeronave com uma câmera fotográfica acoplada para adquirir fotos da paisagem de Centocelli, Italia. A manobrabilidade do avião permitiu o controle da velocidade, altitude e direção necessárias para a aquisição sistemática das fotos aéreas (Campbell, 2002).

A Primeira Guerra Mundial foi o momento que marcou o início da aquisição de imagens aéreas de forma contínua. Foi durante a guerra que diversos equipamentos foram desenvolvidos especificamente para a aquisição de imagens aéreas, enquanto profissionais eram treinados para adquirir, processar e interpretar essas imagens. Inicialmente, as imagens foram utilizadas para mapeamentos topográficos, mas logo em seguida foram utilizadas para levantamentos de solos, mapeamento geológico, levantamentos florestais e agricultura (Campbell, 2002).

Nos dias atuais, os avanços obtidos nas tecnologias de posicionamento global (GPS), sistemas de informações geográficas e no sensoriamento remoto criou a possibilidade de acessar a variabilidade espacial presente na floresta e maneja-la apropriadamente. Segundo Basso et al., (2004), o potencial do sensoriamento remoto para a agricultura e o manejo de florestas advém das relações existentes entre importantes processos biológicos, como fotossíntese, evapotranspiração e outros, com as refletâncias multiespectrais da cobertura vegetal.

Embora imagens óticas possam ser obtidas utilizando fontes de energias independentes, como um flash de uma lâmpada, elas são normalmente obtidas passivamente usando a energia proveniente do Sol. A região do visível é importante para o sensoriamento remoto porque a maioria da energia solar é emitida nesta faixa, e é onde ocorrem as maiores interações dos fenômenos de refletância e absorção com as plantas (Gates & Tantraporn, 1952).

Na região espectral do visível, a alta absorção da energia eletromagnética decorre da presença dos pigmentos nas folhas, principalmente a clorofila, embora os carotenoides, xantofilas e antocianinas também possuam efeitos. Nas florestas tropicais existe um aumento no conhecimento do uso de sensores remotos para determinar os componentes químicos da copa através das diferentes absorções ocorridas nos comprimentos de onda do visível e do infravermelho não termal. Em alguns casos as diferenças entre as feições de interesse são enormes e uma simples análise multiespectral pode diferencia-las (Chambers et al., 2007).

Recentemente, dados digitais de satélites, por exemplo, Landsat TM, tem sido aplicados com sucesso para inventário em grandes áreas. Embora as predições de diâmetros e volume possuem consideráveis incertezas para árvores individuais, a utilização dos dados digitais provenientes dos sensores remotos aplicados a grandes áreas aumenta a precisão dos inventários. Além disso, o sensoriamento remoto fornece dados sobre atributos florestais rapidamente e com baixo custo, permitindo produzir mapas temáticos que podem ser utilizados para diversos fins, como para produção de madeira (McRoberts & Tomppo, 2007).

As estimativas de biomassa e volume de florestas são importantes para os estudos de produtividade e acumulação de energia em ecossistemas terrestre (Wang et al., 1995; Brown et al., 1999; Ryu et al., 2004). Além disso, aumentou muito a necessidade de monitorar os recursos florestais com o objetivo de abordar os problemas relacionados às emissões de dióxido de carbono (Brown, 2002).

Uma dificuldade comum encontrada na aplicação de sensores óticos para inventários florestais refere-se à saturação de informações incorporadas nas imagens em elevados níveis de biomassa ou área foliar (Wulder, 1998; Muukkonen & Heiskanen, 2005; Luther et al., 2006; Sarker & Nichol, 2011; Dube & Mutanga, 2015). Isto é atribuído ao fato de que a imagem ótica capta principalmente as características horizontais de uma copa e é praticamente insensível ao aumento de volume ou composição na camada vertical, uma vez que a cobertura é fechada (Wulder, 1998).

Embora os sensores remotos de alta resolução espacial sejam mais equipados para minimizar a saturação, o problema ainda pode persistir em níveis muito elevados de biomassa (Leboeuf et al., 2007).

2.2. Sensoriamento Remoto por RADAR

Os sensores radargramétricos são considerados uma importante tecnologia na obtenção de dados da superfície terrestre. Desde a década de 1960 os dados de RADAR têm sido reconhecidos como úteis para aplicações militares em regiões tropicais. A posterior liberação dos dados de RADAR para uso civil, nos anos 70, possibilitou a realização de projetos como o RADAMBRASIL e o PRORADAM, na Colômbia, onde imagens de RADAR aerotransportado foram utilizadas para mapeamentos geológicos e de vegetação, entre outros. Mais recentemente, a Shuttle Radar Topography Mission (SRTM) produziu um modelo digital de elevação global cuja grande vantagem, além da sua abrangência global, é possuir uma qualidade homogênea por todo o produto (Rabus et al., 2003).

Os radares atuam com a transmissão e recepção da energia eletromagnética na região denominada de microondas, que devido aos seus maiores comprimentos de onda, são capazes de atravessar nuvens e chuva, e em determinadas condições, dosséis vegetais e solos (Le Toan et al., 2002). Como sistemas ativos, os radares geram energia eletromagnética suficiente para iluminar a cena e registram os ecos refletidos, apresentando-os sobre a forma de uma imagem.

No setor florestal, os dados de RADAR apresentam informações relacionadas com as propriedades biofísicas da vegetação, principalmente sobre sua estrutura e conteúdo hídrico (Imhoff, 1995), este relacionado com a constante dielétrica do alvo. Além disso, outras características inerentes aos sensores também afetam as estimativas de biomassa e volume, como a polarização e o ângulo de incidência (Lu, 2006). Por exemplo, Lucas et al. (2010) ressaltou a sensibilidade das polarizações HH e HV do PALSAR às condições de umidade na superfície, recomendando que a aquisição de dados durante o período de menor umidade no solo/superfície é melhor para estimar a biomassa.

No entanto, nenhum instrumento de sensoriamento remoto é capaz de mensurar diretamente a biomassa ou o conteúdo de carbono, sendo necessários dados *in situ* para estabelecer uma relação entre o sinal captado pelo sensor e a variável de interesse (Rosenqvist et al., 2003).

As ondas eletromagnéticas emitidas pelos sensores consistem de um campo elétrico e outro magnético. Em um espaço livre, estes dois campos estariam perpendiculares um ao outro e transversais à direção de propagação da onda (Elachi & Zyl, 2006). No sensoriamento remoto por RADAR, as microondas transmitidas ou recebidas com o campo elétrico paralelamente à superfície, são ditas horizontalmente polarizadas, enquanto aquelas com o campo elétrico perpendicular à superfície são ditas verticalmente polarizadas.

Os radares de abertura sintética podem obter dados em quatro combinações de polarização: energia transmitida e recebida horizontalmente (HH), energia transmitida e recebida verticalmente (VV), energia transmitida horizontalmente e recebida verticalmente (HV) e energia transmitida verticalmente e recebida horizontalmente (VH) (Coops, 2001). Estas diferentes polarizações apresentam distintas condições de reflectância e aumentam a capacidade do sensor de fornecer dados que permitam estudar as feições na superfície terrestre.

Ademais, outra característica importante na discriminação das feições na superfície terrestre é a resolução espacial do RADAR, a qual é definida pelo tamanho da antena, onde as melhores resoluções espaciais são obtidas com antenas maiores. Visto que os primeiros sensores radares imageadores eram do tipo RAR (Real Aperture Radar), que trabalhavam com as dimensões efetivas da antena, estes apresentavam resoluções espaciais na ordem de algumas centenas de metros a quilômetros de resolução, mesmo para antenas de grandes dimensões. Por conseguinte, foi desenvolvida uma tecnologia denominada de Synthetic Aperture Radar (SAR). Esta tecnologia é baseada na simulação de uma longa antena, obtida através do processamento dos registros de sinais ao longo da linha de vôo, isto é, o sensor registra o eco do mesmo objeto de diferentes posições ao longo do seu trajeto e isto permite localiza-lo devido ao tempo de retorno do pulso eletromagnético, aumentando a sua resolução espacial (Elachi & Zyl, 2006).

Em síntese, uma imagem digital de radar é constituída por pixels com valores numéricos proporcionais à intensidade do eco que retorna à antena do radar. Este eco é denominado retroespalhamento, uma vez que se refere à energia eletromagnética espalhada na direção do radar. O coeficiente de retroespalhamento exemplifica a força de irradiação da microonda emitida e retornada para o sensor, após ter sido espalhada

pelos alvos da superfície. A análise do coeficiente de retroespalhamento permite estimar volume de água contida no solo, volume de biomassa em florestas, condições das ondas no oceano e outros (JAXA, 2012).

Os Radares SARs podem operar em diferentes bandas, que se referem aos comprimentos de onda e frequências das microondas transmitidas e recebidas como eco da superfície terrestre. O tamanho e a densidade dos elementos vegetais têm relação direta no tipo de interação com as microondas incidentes. Pequenos comprimentos de onda, como os das bandas X (comprimento de onda ~ 3 cm) e C (comprimento de onda ~ 6 cm) são particularmente sensíveis ao espalhamento causado na superfície (incluindo folhas, ramos e galhos menores) enquanto os maiores comprimentos de onda da banda L (comprimento de onda ~ 25 cm) e banda P (comprimento de onda ~ 65 cm) interagem com maiores componentes da vegetação, os troncos e a camada superficial do solo (Lucas & Milne, 2001).

2.4 O satélite ALOS

O satélite ALOS foi lançado do centro espacial Tanegashima às 10:33am do dia 24 de janeiro de 2006 e operou até 10:50 do dia 12 de maio de 2012 (Horário padrão Japonês) (JAXA, 2012).

A bordo do satélite ALOS existiam dois sensores óticos (AVNIR-2 e PRISM) desenvolvidos pela Agência Japonesa de Exploração Aeroespacial (JAXA) e o sensor ativo PALSAR desenvolvido pelo Ministério Japonês de Economia, Comércio e Indústria em parceria com a JAXA (Figura 2).




Figura 2 - Satélite ALOS (JAXA, 2012).

O satélite ALOS gira em torno da terra em uma órbita sol-síncrona, na qual o plano orbital e a direção do Sol são sempre as mesmas, permitindo ciclos fixos e a possibilidade de monitorar locais na terra em intervalos regulares. O satélite orbitou a uma altitude de 691.65 km e com 98.16 graus de inclinação, o que permitiu ao satélite girar sobre a terra quatorze vezes por dia (JAXA, 2012).

A seguir, encontram-se as descrições dos principais sensores a bordo do satélite ALOS, conforme JAXA (2012).

O sensor Advanced Visible and Near Infrared Radiometer type 2 (AVNIR-2) possui quatro bandas com resolução espacial de 10m, operando na região do visível e do infravermelho próximo, com resolução radiométrica de 8 bits. Foi desenvolvido para propiciar a elaboração de mapas de cobertura do solo, classificação do uso da terra que são necessários para o monitoramento ambiental e demais propósitos.

O sensor AVNIR-2 possui um ângulo de apontamento de mais ou menos 44°, para observação imediata de áreas afetadas por desastres naturais. Sua tecnologia foi aprimorada a partir do sensor AVNIR a bordo do Advanced Earth Observing Satellite (ADEOS), lançado em 1996. A tabela 1 mostra as principais características do sensor AVNIR-2.

Tabela 1 - Características do sensor AVNIR-2.

Número de bandas	4
Comprimento de onda	Banda 1 : 0.42 ~ 0.50 μm
	Banda 2 : .052 ~ 0.60 μm
	Banda 3 : 0.61 ~ 0.69 μm
	Banda 4 : 0.76 ~ 0.89 μm
Resolução espacial	10 m (nadir)
Largura da faixa	70 km (nadir)
Ângulo de apontamento	$\pm 44^\circ$
Resolução radiométrica	8 bits

Fonte: JAXA (2012)

O sensor Phased Array type L-Band Synthetic Aperture Radar (PALSAR), é um sensor de microondas ativo, que não é afetado pelas condições de nebulosidade e operável durante o dia e a noite. O sensor PALSAR foi melhorado a partir do sensor de abertura sintética (SAR) a bordo do satélite JERS-1.

Algumas funções implementadas no PALSAR, como a múltipla polarização, melhoram a precisão das análises e contribuem efetivamente para diversos estudos. A tabela 2 mostra as principais características do sensor PALSAR.

Tabela 2 - Características do sensor PALSAR.

Modo	Fino		ScanSAR	Polarimétrico
Frequência de centro	1270 MHz (L-banda)			
Bandwidth	28 MHz	14 MHz	14, 28 MHz	14 MHz
Polarização	HH ou VV	HH+HV ou VV+VH	HH ou VV	HH+HV+VH+VV
Ângulo de incidência	8 ~ 60°	8 ~ 60°	18 ~ 43°	8 ~ 30°
Resolução em alcance (range)	7 ~ 44 m	14 ~ 88 m	100 m (multi look)	24 ~ 89 m
Largura da faixa	40 ~ 70 km	40 ~ 70 km	250 ~ 350 km	20 ~ 65 km
Taxa de transmissão de dados	240 Mbps	240 Mbps	120 Mbps, 240 Mbps	240 Mbps

Fonte: JAXA (2012)

O sensor PRISM é um sensor ótico exclusivamente usado para observar áreas com alta resolução espacial (2,5m). Os dados obtidos são utilizados para produzir um modelo digital de elevação altamente acurado. Ele possui três sistemas óticos de visada, um para frente, um no nadir e outro para trás, e sua observação simultânea permitia a aquisição de dados topográficos. A tabela 3 mostra as principais características do sensor PRISM.

Tabela 3 - Características do sensor PRISM

Número de bandas	1 (Pancromática)
Comprimento de onda	0.52 ~ 0.77 μm
Sistema ótico	3 (Nadir, para frente, para trás)
Relação base/altura	1.0 (entre visadas para frente e para trás)
Resolução espacial	2.5 m
Largura da faixa	70 km (nadir) 35 km (modo Triplet)
Ângulo de apontamento	$\pm 1.5^\circ$ (transversal à trajetória no modo Triplet)
Resolução radiométrica	8 bits

Fonte: JAXA (2012)

2.5 Redes Neurais Artificiais (RNA)

A rede neural artificial é uma estrutura de processamento de informações com elementos de processamento (os quais podem possuir uma memória local e podem realizar processamento de operações das informações localizadas) paralelamente distribuídos, juntamente interconectados por canais unidirecionais chamados de conexões. Cada elemento de processamento tem apenas uma saída de sinal, porém com quantas ramificações forem desejadas, mas todas elas carregando o mesmo sinal, o sinal de saída do elemento de processamento, o que pode ser de qualquer tipo matemático desejado. No entanto, todo o processamento realizado em um elemento de processamento deve ser estritamente local, ou seja, ele deve depender apenas dos valores atuais do sinal de entrada chegando via conexões e sobre valores armazenados na sua memória local (Hecht-Nielsen, 1989).

Os elementos de processamento são inspirados nos neurônios biológicos do sistema nervoso. Embora os neurônios possam ser bem mais lentos do que os circuitos elétricos, o cérebro é capaz de realizar muitas tarefas bem mais rápido do que um computador (Hopfield, 1988), devido principalmente às estruturas massivamente paralelas de simples processamentos encontradas nas redes neurais biológicas (Yegnanarayana, 2006). No entanto, não se espera que os modelos de redes neurais

artificiais cheguem de alguma maneira perto do desempenho das redes de neurônios biológicos, devido ao fato de ainda não se entender completamente o funcionamento do neurônio biológico e suas interconexões. Além de ser extremamente difícil simular o número de neurônios e suas interconexões como existem na rede neural biológica e suas operações de modo assíncrono natural (Yegnanarayana, 2006).

Um esquema básico de uma rede neural artificial é apresentado na figura 3.

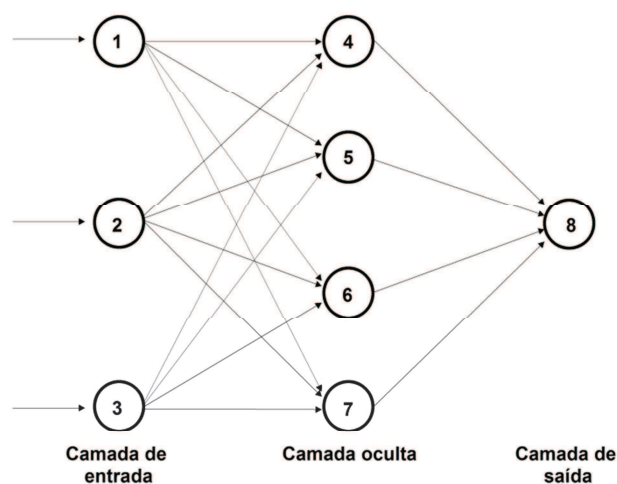


Figura 3 - Estrutura de uma rede neural artificial.

As redes neurais artificiais são geralmente organizadas em camadas de unidades processamento ou neurônios. Os neurônios de uma camada são similares, de modo que todos eles possuem a mesma dinâmica de ativação e funções de saída. As conexões podem ser feitas entre neurônios de uma camada com os neurônios da outra camada (conexões entre camadas), como também podem ser feitas entre neurônios dentro da mesma camada (conexões dentro da camada) ou podem ser feitas tanto entre camadas quanto dentro da mesma camada na rede neural. Mais ainda, as conexões entre as camadas e entre os neurônios podem ser feitas da maneira *feedforward* ou na maneira *feedback*. Na rede neural com modo *feedback* um mesmo neurônio pode ser visitado mais de uma vez (Yegnanarayana, 2006).

Os termos aprendizado ou treinamento de uma rede neural podem ser vistos como uma busca no espaço dos pesos das conexões, de maneira sistemática, para

determinar o vetor de peso que leva para uma solução ótima (mínima ou máxima) de uma função objetivo. Essa busca depende do critério escolhido. Existem diversos critérios, os quais incluem a minimização da soma de quadrados do erro, entropia relativa, máxima verossimilhança, gradiente descendente, etc (Hassoun, 1995, apud Yegnanarayana, 2006).

O aprendizado pode ser feito de maneira supervisionada ou não supervisionada. No aprendizado supervisionado a solução desejada é conhecida e informada à rede neural, portanto o ajuste dos pesos nas interconexões da rede neural para minimizar o erro é baseado no desvio entre a saída atual obtida e a saída desejada, fornecida à rede neural. A aprendizagem não supervisionada descobre as características em um conjunto de padrões e os organiza conformemente. Não existe nenhuma saída externa desejada para este caso (Yegnanarayana, 2006).

Um algoritmo de treinamento é utilizado para minimizar a função global do erro a partir dos ajustes dos pesos da rede neural. O algoritmo BFGS tem obtido muito sucesso em estudos publicados (Statsoft, Inc, 2015). É um método classificado como quase-Newton, que busca fazer uma aproximação iterativa da inversa da matriz hessiana. As técnicas mais recomendadas para treinar redes neurais artificiais são os algoritmos BFGS e *Scaled Conjugate Gradient* (Bishop, 1995, apud Statsoft, Inc, 2015).

A rede neural *Perceptron de Múltiplas Camadas* com o algoritmo de retropropagação é o mais utilizado em áreas como reconhecimento de padrões, processamento de fala, aproximação de funções e outros. Neste caso, o algoritmo de retropropagação do erro utiliza um treinamento supervisionado para ajustar os pesos. O treinamento utiliza o método *feedforward*, neste método ocorre à propagação a frente do padrão de entrada, o processamento pela rede neural e a retropropagação do erro apurado pela saída desejada.

No setor florestal, existem estudos que demonstram a eficiência das redes neurais.

Binoti et al., (2015) evidenciaram a capacidade da RNA para realizar prognose da produção volumétrica ao estimar o volume de madeira em povoamentos de

eucaliptos, utilizando variáveis numéricas – idade, área basal, volume – e categóricas – classes de solo, textura, tipo de espaçamento, relevo, projeto e clone – de parcelas permanentes e concluíram que todas as variáveis foram importantes, com ressalva para as variáveis clone, volume e área basal como mais importantes. Outro estudo demonstrou a eficiência das redes neurais para estimar a altura total de árvores utilizando as variáveis independentes – classes de solo, clone, dap, idade e altura dominante média da parcela – de parcelas permanentes de inventário florestal contínuo (Binoti et al., 2013). Este trabalho comprovou que é possível reduzir o número de medições em campo necessárias para estimar a altura e com isso diminuir o custo de inventários florestais.

No nível de árvores individuais, Silva et al., (2009) compararam o ajuste do modelo volumétrico de Shumacher & Hall (1933) por diferentes algoritmos com a aplicação da RNA para estimar o volume de madeira de eucalipto em função do diâmetro, altura total e do clone. Concluíram que embora o modelo de Shumacher & Hall possa ser usado na sua forma linear, com boa representatividade e sem tendenciosidade, este deveria ser ajustado para cada clone, enquanto a RNA englobaria todos os clones em apenas um modelo. Ademais, Binoti et al., (2014) estudaram diferentes configurações de RNA para estimar o volume de árvores, demonstrando que com poucos ou apenas um neurônio a RNA foi eficiente.

Leite et al. (2009) em seu estudo, concluíram que a RNA foi mais eficiente para estimar o diâmetro sem casca e o diâmetro do cerne de indivíduos de *Tectona grandis*, quando comparada com o método mais utilizado no Brasil, o modelo de afilamento desenvolvido por Kozack et al. (1969).

3. MATERIAL E MÉTODOS

O presente estudo foi uma continuidade do trabalho realizado por Oliveira (2011). Portanto, o pré-processamento dos dados trabalhados foi idealizado por este autor e detalhado em seu trabalho. Aqui será feito um resumo do que foi considerado mais relevante e que permitirá ao leitor compreender o presente estudo.

3.1. Área de estudo

O estudo foi conduzido em povoamentos de eucalipto localizado nos municípios de Belo Oriente, Santana do Paraíso, Ipaba e Caratinga, Minas Gerais (Figura 4). Na figura 4 é mostrada também a distribuição das 206 parcelas de inventário ao longo da área de estudo.

O plantio, com finalidade para produção de celulose, é formado por clones de eucalipto, com espaçamento de 3 x 2 m, idade de 4 a 8 anos, altura média de 26 m, em uma área total de 83.712 ha. As áreas estão localizadas em um relevo variando de plano a levemente ondulado.

Segundo a classificação de Köppen, o clima local é do tipo Aw, considerado temperado chuvoso-mesotérmico, com precipitação média anual de 1.153 mm. A temperatura média anual varia de 20 a 23°C. O solo é classificado como um Neossolo Flúvio distrófico típico, localizado em área de baixada com relevo levemente ondulado (IBGE, 2001).

3.2. Imagens e softwares

Para o desenvolvimento da pesquisa foram utilizadas imagens do satélite ALOS provenientes dos sensores AVNIR-2 e PALSAR. As datas de obtenção das imagens foram 27 de maio de 2009 para o sensor AVNIR-2 e 02 de maio de 2009 para o sensor PALSAR.

As imagens do sensor AVNIR-2 foram submetidas à técnica de correção dos efeitos atmosféricos, sugerida por Chavez (1975), para remoção do efeito de dispersão da energia eletromagnética nas partículas de água da atmosfera. Foi empregado o software ERDAS para realizar o refinamento da correção geométrica.




Figura 4 - Localização da área de estudo nos municípios de Belo oriente, Santana do Paraíso, Ipaba e Caratinga-MG, com identificação das parcelas de inventário florestal (Oliveira, 2011).

As imagens do sensor PALSAR, originalmente com resolução radiométrica de 16 bits, foram convertidas para 8 bits, e posteriormente calculado o coeficiente de retroespalhamento (Henderson e Lewis, 1998, apud Oliveira, 2011), produzindo imagens polarimétricas (HH, HV, VV e VH) na mesma resolução da AVNIR-2.

3.3. Inventário florestal

O inventário florestal foi realizado no período de fevereiro a setembro de 2009. Os dados volumétricos foram obtidos a partir da medição e modelagem dos dados de altura e diâmetro. As medidas de biomassa foram obtidas pelo método destrutivo a

partir de árvores pré-selecionadas de representatividade dos locais. No apêndice encontram-se os dados de volume e biomassa de eucaliptos.

3.4. Seleção das parcelas e extração dos valores numéricos dos pixels

Foram utilizadas 206 parcelas situadas em áreas imageadas pelos dois sensores AVNIR-2 e PALSAR com idades superiores a cinco anos. As localizações geográficas das parcelas foram representadas por um ponto central à parcela. Como estas eram quadradas, de tamanhos e orientações diferentes, para a extração dos valores numéricos foi gerada uma máscara do mesmo tamanho. Como a sobreposição da máscara sobre o local abrangia diferentes números de pixels, realizou-se uma interseção e uma média ponderada dos valores numéricos de cada pixel por sua área de contribuição (Figura 2).




Figura 5 - Máscara para extração do valor numérico da parcela (Oliveira, 2011).

3.5. Estimativas do volume e da biomassa a partir das imagens AVNIR-2 e PALSAR

Neste estudo, o procedimento empregado para estimar a biomassa aérea e o volume com os valores das imagens digitais foi o de Redes Neurais Artificiais (RNA). Para tal, foi considerado como variável dependente os dados de biomassa e volume obtidos por meio do inventário florestal e, como independentes, os valores numéricos digitais extraídos das quatro bandas das imagens AVNIR-2 e das quatro polarizações do PALSAR conforme descrição nas Tabelas 4 e 5.

Tabela 4 - Variáveis AVNIR-2 utilizadas nas análises estatísticas

Variável	Descrição
AV1	Valor numérico na Banda1 (Azul)
AV2	Valor numérico na Banda2 (Verde)
AV3	Valor numérico na Banda3 (Vermelho)
AV4	Valor numérico na Banda4 (Infravermelho Próximo)

Tabela 5 - Variáveis do sensor PALSAR utilizadas nas análises estatísticas

Variável	Descrição
L_{HH}	Valor numérico na polarização HH
L_{HV}	Valor numérico na polarização HV
L_{VV}	Valor numérico na polarização VV
L_{VH}	Valornumérico na polarização VH

Neste estudo, o treinamento das redes foi do tipo supervisionado. As redes foram treinadas para estimar os valores de biomassa aérea e volume a partir dos valores das reflectâncias médias das parcelas experimentais nas quatro bandas espectrais (AV1, AV2, AV3 e AV4) do sensor AVNIR-2 e nas quatro polarizações do sensor PALSAR (L_{HH} , L_{HV} , L_{VV} e L_{VH}).

Para analisar o comportamento das redes neurais, ajustou-se 200.000 redes tipo Perceptrons de Múltiplas Camadas (MLP) para volume e biomassa aérea separadamente, utilizando os dados dos sensores AVNIR-2 e PALSAR. Para tal, variou-se o número de neurônios na camada oculta de 1 até 50 e feitas combinações com as funções exponencial, tangente hiperbólica, logística e identidade nas camadas oculta e de saída. Com isso, foi possível calcular a média dos erros obtidos pela validação para cada combinação do número de neurônios com as funções de ativação. Isto permitiu

analisar o comportamento do erro de validação perante as diferentes combinações e determinar quais arquiteturas apresentavam maiores estabilidades para realizar a generalização.

Em seguida, foram treinadas 5000 redes MLP, para a biomassa aérea e o volume separadamente, em função das variáveis dos sensores AVNIR-2, do PALSAR e do AVNIR-2 e PALSAR juntas. Das 5000 RNA treinadas, foi selecionada apenas a melhor rede, em função do coeficiente de correlação entre os valores observados e os valores estimados pela RNA, pela distribuição dos erros e pelo valor do RMSE%.

$$\text{Sendo RMSE\%} = \sqrt{\frac{\sum(\hat{y}_i - y_i)^2}{n}} \cdot \frac{100}{\bar{y}_i}$$

onde,

\hat{y}_i = valor estimado i

y_i = valor observado i

\bar{y}_i = média dos valores observados

n = número de parcelas

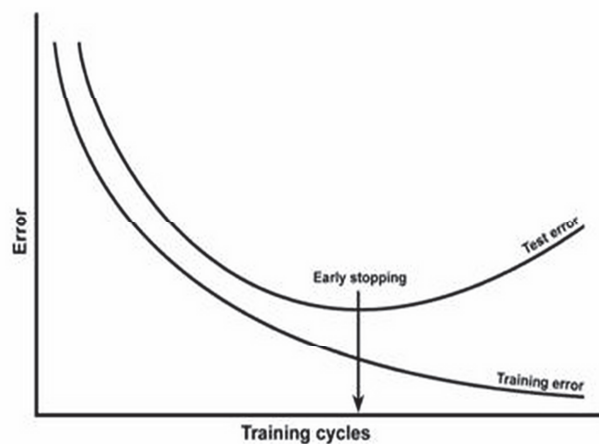
As parcelas foram divididas, aleatoriamente, em amostras de treinamento, teste e validação. Primeiro foram utilizadas 50% das parcelas para treinamento, 25% para teste e 25% para validação. Em seguida, 40% para treinamento, 30% para teste e 30% para validação. Esse procedimento prosseguiu até que 10% das parcelas fossem utilizadas para treinamento e as demais divididas igualmente entre teste e validação.

As redes neurais artificiais foram treinadas pelo software Statistica 12 utilizando o método BFGS como a base matemática para o algoritmo de retropropagação e a função de soma dos quadrados para calcular o erro. A definição da arquitetura das redes, ou seja, número de neurônios por camada e número de camadas,

foram otimizados pela ferramenta Intelligent Problem Solver (IPS), do software Statistica 12 (STATSOFT, Inc, 2015).

4. RESULTADOS E DISCUSSÃO

No software STATISTICA 12 as divisões das parcelas entre amostras de treinamento, teste e validação contribuem para evitar o “overfitting”. Os dados separados para o teste não são utilizados para o treinamento em si da rede neural. Eles fazem parte de um processo iterativo de averiguação do erro estimado, utilizado durante o treinamento. Conforme mostra a figura 6, durante o treinamento, se o erro entre os valores estimados e os observados aumentar por um número de ciclos, o treinamento da rede neural é interrompido, retornando ao resultado obtido no ciclo de menor erro para a amostra teste.



*Adaptado do STATISTICA 12

Figura 6 – Parada do treinamento utilizando uma amostra para teste.

4.1. Treinamento de 200.000 redes neurais MLP para estimar a variável volume

O treinamento de 200.000 redes MLP para estimar o volume resultou em uma média de 250 redes neurais para cada arquitetura de neurônios na camada oculta, função de ativação da camada oculta e da camada de saída. A seguir são mostrados os resultados referentes a cada combinação.

Utilizando a função tangente hiperbólica (camada oculta) e identidade (camada de saída), a Figura 7a mostra que com mais de nove neurônios na camada oculta o erro de validação aumentou, em seguida, no décimo segundo neurônio ele retornou ao mesmo patamar, porém, logo em seguida aumentou novamente. Essa situação é conhecida como “overfitting”, onde a rede neural começou a memorizar os dados de treinamento e apresentar piores resultados para a generalização.

Segundo Tetko et al., (1995), enquanto um número suficiente de neurônios pode fazer uma boa predição, o excesso destes faz com que a rede neural aprenda as tendências e ruídos dos dados de treinamento, diminuindo sua capacidade de generalização. Portanto, conforme a figura 7a, o ideal seria um número máximo de nove neurônios na camada oculta para uma rede neural com essa arquitetura de funções de ativação.

Deste modo, o critério definido para escolher o número ideal de neurônios na camada oculta foi baseado no momento em que o erro de validação estabilizou ou apresentou apenas um pequeno decréscimo ao longo do acréscimo de mais neurônios.

Na Figura 7b, com a mudança da função de ativação da camada de saída para logística, o erro de validação diminuiu até a quantidade de trinta e um neurônios na camada oculta. No entanto, foi possível observar que a partir do décimo sexto neurônio ocorreu pouca diminuição do erro, com pequena diferença para uma configuração com trinta e um neurônios. Portanto, considerou-se que uma rede neural com esta arquitetura de funções deveria ter no máximo dezesseis neurônios na camada oculta. Além disso, quando há um aumento da complexidade de uma rede neural, também aumenta o custo computacional, principalmente ao utilizar o algoritmo de treinamento BFGS.

No caso da Figura 7c, onde se usou a função tangente hiperbólica, foram propostos dezoito neurônios. A partir desse ponto, aumentou muito o grau de complexidade da rede para um ganho diminuto no erro de validação.

Em seguida, devido aos altos valores de erros encontrados com a função exponencial para ativação da camada de saída, a escala do gráfico não foi ajustada (Figura 7d). Foi possível observar que a função exponencial na camada de saída apresentou locais de “overfitting” ao longo do espaço de soluções. Em virtude dessa falta de estabilidade, a arquitetura com função tangente hiperbólica para a camada oculta e função exponencial para ativação da camada de saída foi desconsiderada do treinamento de redes neurais para estimar volume.

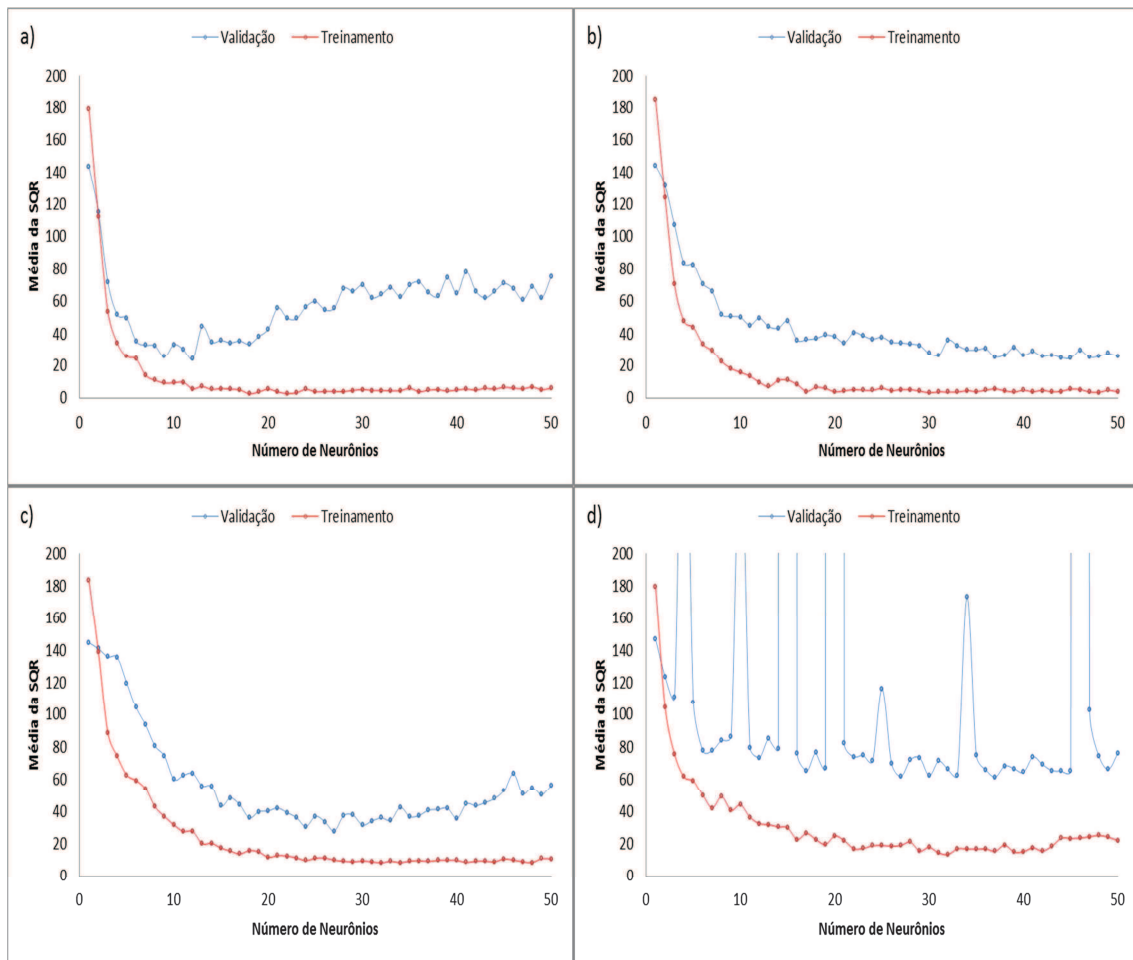


Figura 7 - Gráficos dos comportamentos dos erros de validação e treinamento por números de neurônios na camada oculta para estimar volume. Função tangente hiperbólica na camada oculta e de saída: a) Identidade; b) Logística; c) Tangente hiperbólica; d) Exponencial.

Nas análises das funções logística (camada oculta) e identidade (camada de saída), foi possível observar que a perda na capacidade de generalização da rede iniciou-se a partir do quinto neurônio Figura 8a. Como o número de variáveis independentes do modelo são oito, o “overfitting” aconteceu com um número pequeno de neurônios. Em seguida, ao mudar a função da camada de saída para logística, ocorreu um aumento do número de neurônios antes da estabilização, que agora foram onze neurônios (Figura 8b). Ainda mais, ao mudar a função de saída para tangente hiperbólica, a estabilização ocorreu somente no trigésimo sétimo neurônio (Figura 8c). Essa grande variação demonstra a dificuldade em prever uma quantidade ideal de neurônios na camada oculta, considerando somente as funções de ativação ou número de variáveis de entrada. A análise exhaustiva dos dados nesse caso só foi possível devido ao reduzido número de parcelas e à rápida convergência do algoritmo BFGS. Como alternativa, existem alguns métodos de otimização do número de camadas e de neurônios na rede neural artificial,

conforme Stathakis (2009), que comparou diferentes modelos e demonstrou o potencial dos algoritmos genéticos para determinar a melhor arquitetura.

Novamente, a função exponencial na camada de saída apresentou baixa estabilidade, mesmo para pequenas quantidades de neurônios na camada oculta (Figura 8d).

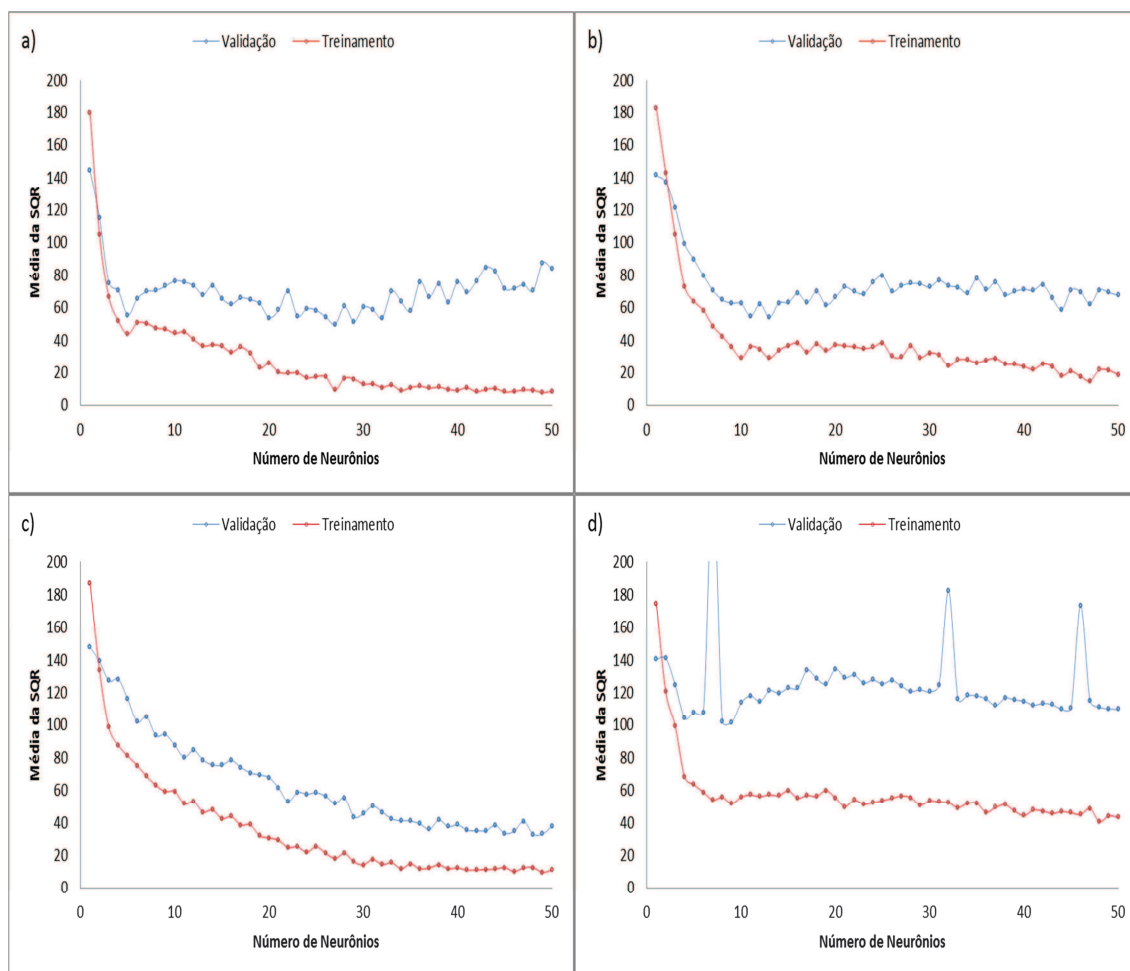


Figura 8 - Gráficos dos comportamentos dos erros de validação e treinamento por números de neurônios na camada oculta para estimar volume. Função logística na camada oculta e de saída: a) Identidade; b) Logística; c) Tangente hiperbólica; d) Exponencial.

Conforme pode ser observado nas Figuras 9a, 9b, 9c e 9d, os erros obtidos para as parcelas de validação com a função exponencial como ativação da camada oculta foram maiores do que os obtidos com as demais funções. Novamente, a função exponencial para a camada de saída acarretou em erros elevados para estimar o volume.

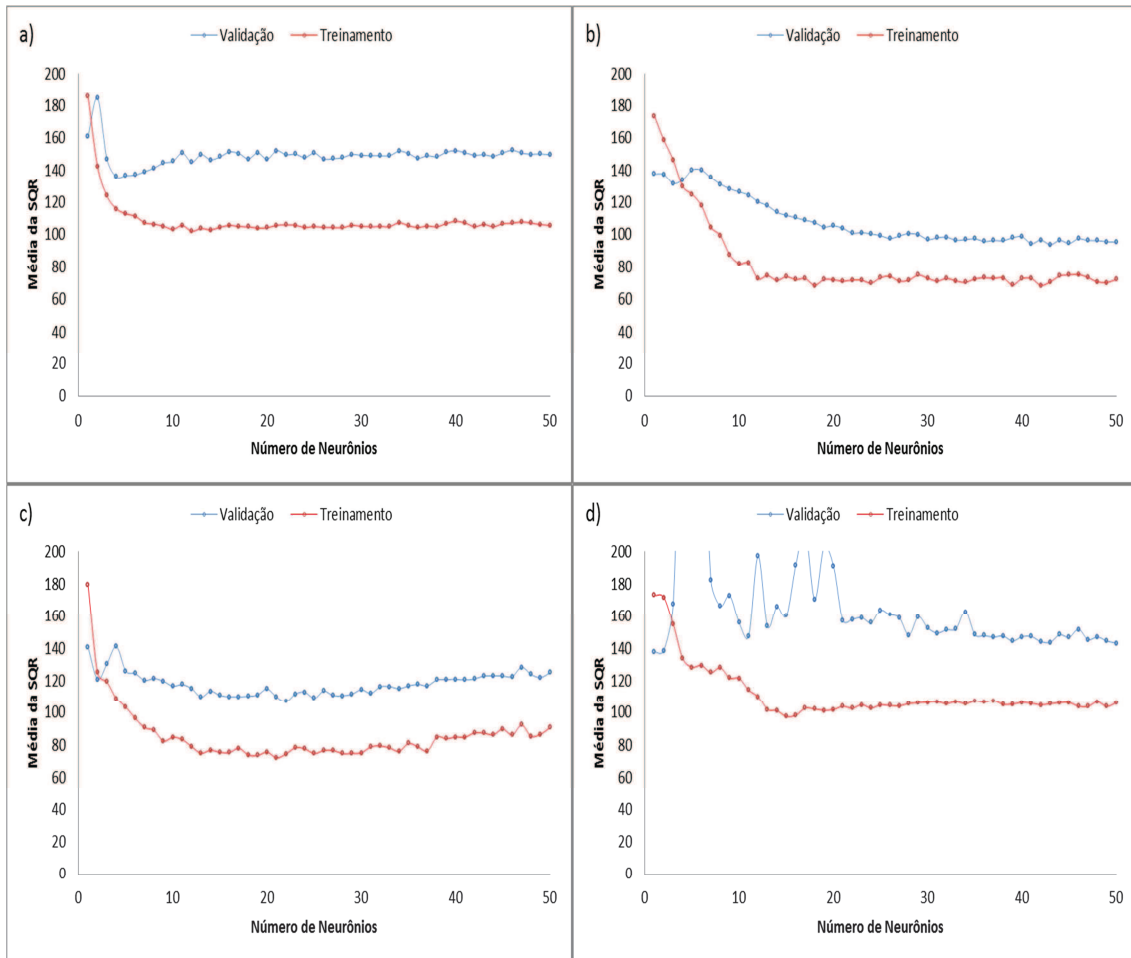


Figura 9 - Gráficos dos comportamentos dos erros de validação e treinamento por números de neurônios na camada oculta para estimar volume. Função exponencial na camada oculta e de saída: a) Identidade; b) Logística; c) Tangente hiperbólica; d) Exponencial.

4.2. Treinamento de 200.000 redes neurais MLP para estimar a variável biomassa

Em seguida são apresentados os resultados obtidos do treinamento de 200.000 redes MLP para estimar a biomassa aérea. Foram obtidas em média, 250 redes neurais para cada arquitetura de neurônios na camada oculta, função de ativação da camada oculta e da camada de saída.

A análise da Figura 10a mostrou que a rede neural com as funções tangente hiperbólica (camada oculta) e identidade (camada de saída) apresentou um número ideal de nove neurônios na camada oculta para evitar o “overfitting” nas estimativas de biomassa. Nota-se que a diferença entre o erro de validação com quatorze neurônios não justifica o aumento de complexidade na rede. Na rede neural da Figura 10b (função logística), a estabilização do erro de validação ocorreu a partir do vigésimo terceiro neurônio. O mesmo pode ser observado na figura 10c (função tangente hiperbólica), na

qual a estabilização do erro de validação também ocorreu no vigésimo terceiro neurônio. A função exponencial apresentou novamente tendência para “overfitting” (Figura 10d). Com isso, essa arquitetura de funções não foi utilizada para o treinamento das redes neurais para estimar a biomassa aérea.

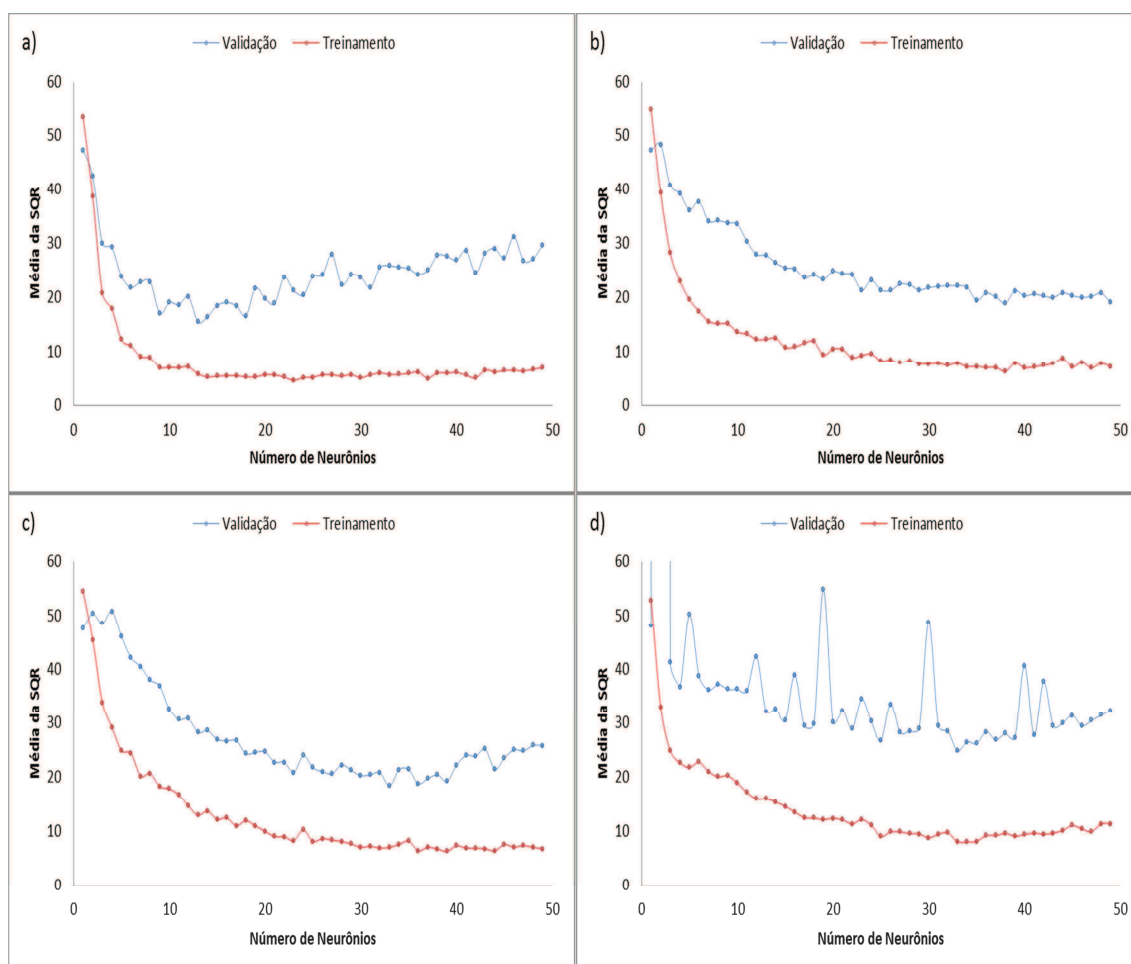


Figura 10 - Gráficos dos comportamentos dos erros de validação e treinamento por números de neurônios na camada oculta para estimar biomassa. Função tangente hiperbólica na camada oculta e de saída: a) Identidade; b) Logística; c) Tangente hiperbólica; d) Exponencial.

Na rede neural da Figura 11a, com a função logística (camada oculta) e identidade (camada de saída), o erro de validação estabilizou a partir do quarto neurônio, metade do número de variáveis de entrada. Já na rede neural, com a função logística para as duas camadas, o erro de validação estabilizou no décimo neurônio (Figura 11b). Analogamente, na rede neural com as funções logística e tangente hiperbólica, a estabilização do erro das parcelas de validação ocorreu somente no trigésimo nono neurônio, sendo que ainda houve um pequeno decréscimo do erro de validação até o quadragésimo quinto neurônio (Figura 11c). A análise da Figura

11d mostrou novamente a instabilidade que existiu na rede neural com uma função exponencial na camada de saída.

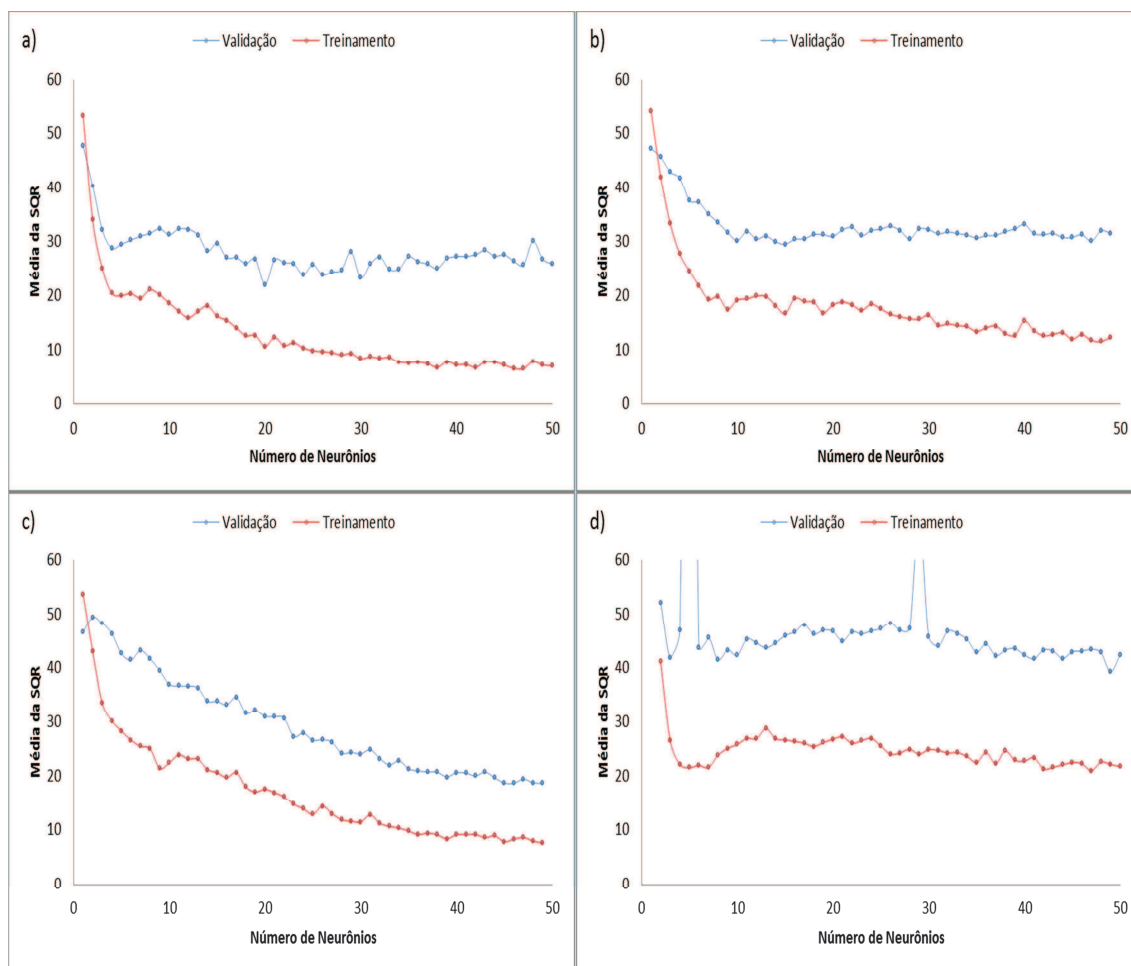


Figura 11 - Gráficos dos comportamentos dos erros de validação e treinamento por números de neurônios na camada oculta para estimar biomassa. Função logística na camada oculta e de saída: a) Identidade; b) Logística; c) Tangente hiperbólica; d) Exponencial.

A análise das Figuras 12a, 12b, 12c e 12d mostraram que as redes neurais com uma função exponencial (camada oculta) apresentaram os maiores erros de validação entre as funções analisadas. Visto que os resultados apresentados nos gráficos anteriores são as médias das diferentes redes treinadas, a casos em que uma rede neural com uma função exponencial, tanto na camada oculta quanto na de saída, pode apresentar resultados iguais ou superiores às redes treinadas com as outras funções. No entanto, devido principalmente à susceptibilidade para ocorrência do “overfitting”, estas não foram escolhidas para realizar as estimativas de volume e biomassa.

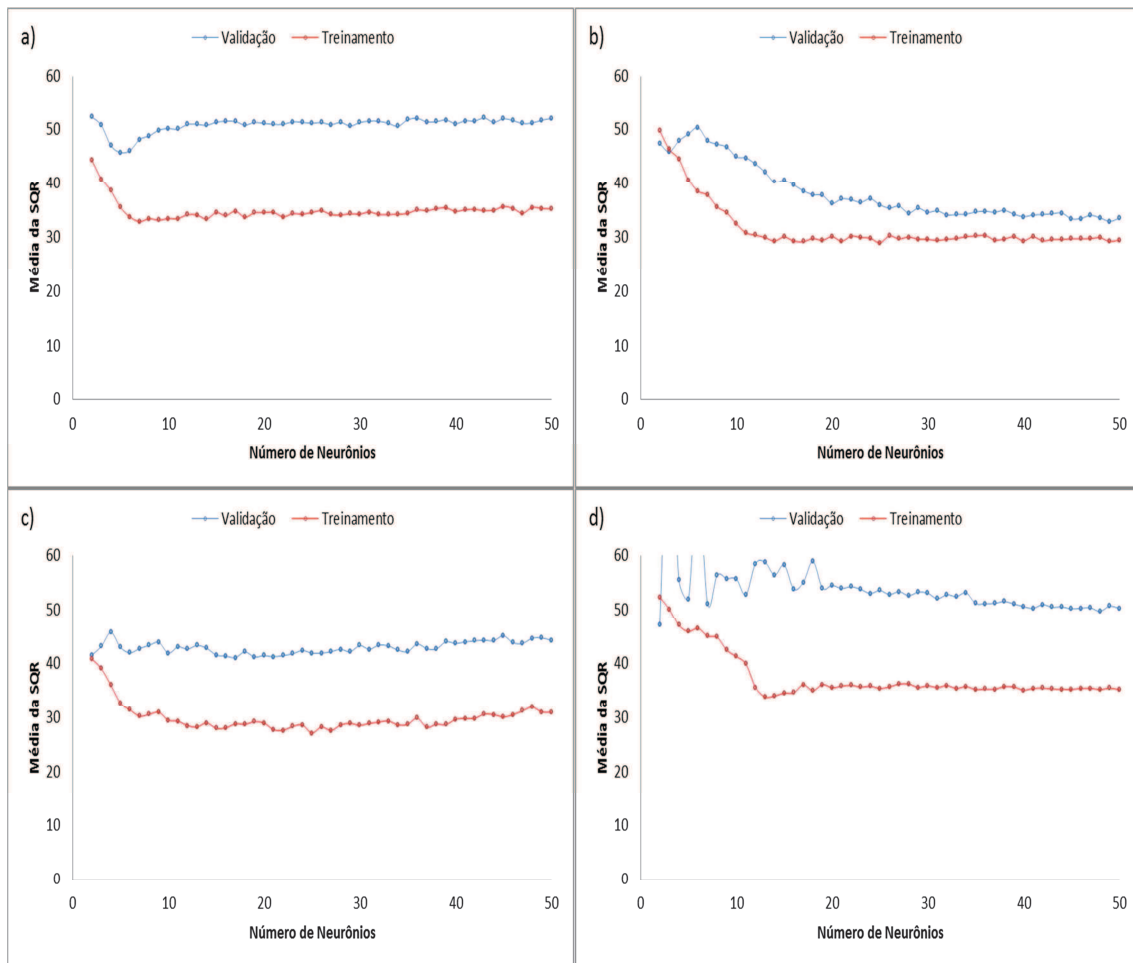


Figura 12 - Gráficos dos comportamentos dos erros de validação e treinamento por números de neurônios na camada oculta para estimar biomassa. Função exponencial na camada oculta e de saída: a) Identidade; b) Logística; c) Tangente hiperbólica; d) Exponencial.

As Tabelas 6 e 7 contêm os resultados obtidos para cada combinação de arquitetura das redes neurais, evidenciando o número máximo ideal de neurônios para cada situação.

No entanto, o critério para selecionar a melhor rede neural para cada situação foi sempre o de optar pelas redes neurais com os menores números de neurônios na camada oculta, quando estas possuíam resultados para as parcelas de validação semelhantes àsquelas de maior complexidade.

Tabela 6 - Número máximo de neurônios para cada arquitetura de rede neural nas estimativas de volume

Função da camada oculta	Função da camada de saída	Nº de neurônios até:
Tangente hiperbólica	Identidade	9
Tangente hiperbólica	Logística	31
Tangente hiperbólica	Tangente hiperbólica	18
Logística	Identidade	5
Logística	Logística	11
Logística	Tangente hiperbólica	37

Tabela 7- Número máximo de neurônios para cada arquitetura de rede neural nas estimativas de biomassa

Função da camada oculta	Função da camada de saída	Nº de neurônios até:
Tangente hiperbólica	Identidade	9
Tangente hiperbólica	Logística	23
Tangente hiperbólica	Tangente hiperbólica	23
Logística	Identidade	4
Logística	Logística	10
Logística	Tangente hiperbólica	39

4.3. Estimativas de volume e biomassa com 5.000 redes neurais

Na sequência são apresentados os resultados do treinamento de 5.000 redes neurais, nas quais foram selecionadas aquelas que apresentaram os melhores resultados para estimar o volume e a biomassa aérea. Os critérios para escolha da rede foram o número de neurônios na camada oculta, os valores de RMSE%, coeficiente de correlação e distribuição dos resíduos obtidos para as parcelas de validação.

4.3.1. Estimativas de volume com 5.000 redes neurais

Inicialmente, foram utilizadas, aleatoriamente, 104 parcelas, para estimar o volume em função das quatro bandas do sensor AVNIR-2. Uma rede neural MLP 4-7-1 com função de ativação tangente hiperbólica para a camada oculta e logística para a camada de saída foi escolhida. A Figura 13 mostra os resultados obtidos, os quais foram calculados para as parcelas de validação. Nota-se que os resíduos ficaram entre -4 e 20%. O coeficiente de correlação encontrado foi de 0,96 e o RMSE% foi de 3,9%.

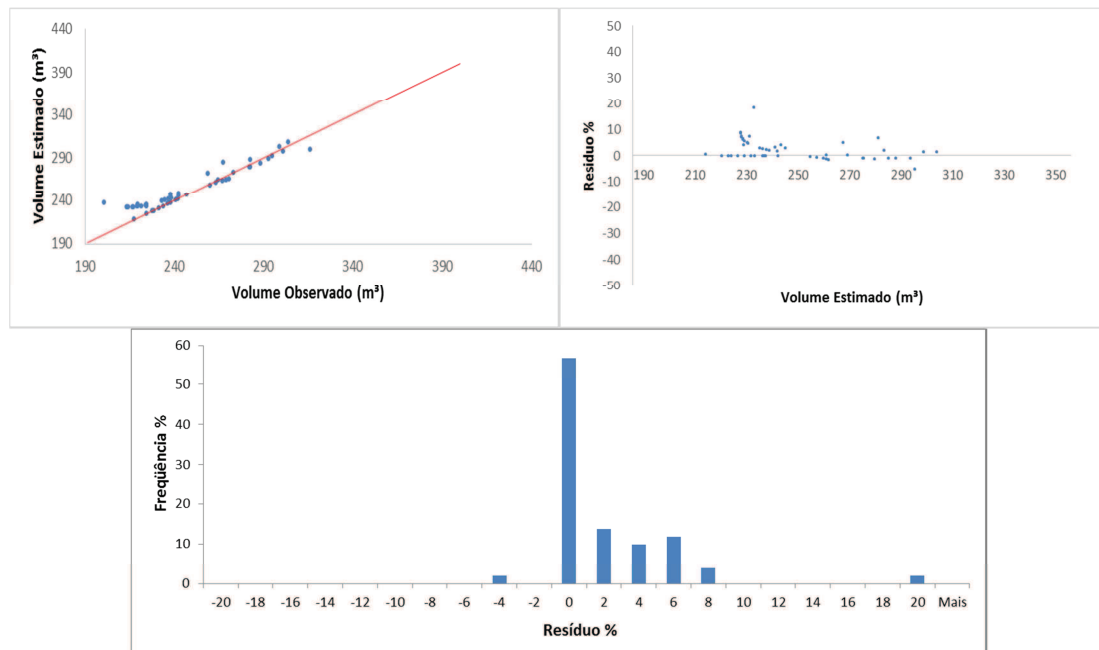


Figura 13- Gráficos de resíduos utilizando o sensor AVNIR-2 para estimar volume.

A análise de sensibilidade global feita pelo software STATISTICA 12 mostrou que as seguintes variáveis, em ordem decrescente de importância, que tiveram as maiores influências no ajuste dessa rede neural foram: AV2; AV4; AV1; AV3.

Para estimar o volume em função das quatro polarizações do sensor PALSAR, com as mesmas parcelas utilizadas anteriormente, selecionou-se uma rede neural MLP 4-10-1 com função de ativação logística para a camada oculta e logística para a camada de saída. Obteve-se um RMSE% de 7,93, coeficiente de correlação de 0,72 e resíduos entre -12 a 16% para as parcelas de validação (Figura 14). A análise global de sensibilidade teve o seguinte resultado em ordem decrescente de importância: L_{VV} ; L_{VH} ; L_{HH} ; L_{HV} .

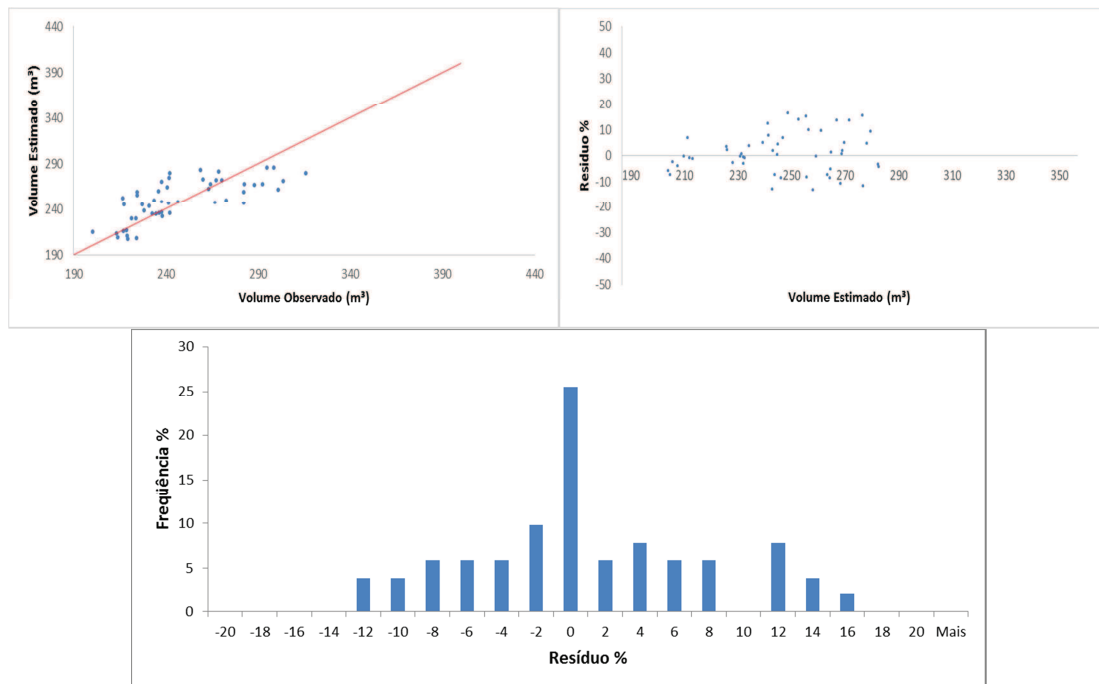


Figura 14 - Gráficos de resíduos utilizando o sensor PALSAR para estimar volume.

O melhor resultado para estimar o volume foi obtido utilizando os sensores AVNIR e PALSAR juntos. A rede neural MLP 8-7-1 com função de ativação tangente hiperbólica para a camada oculta e identidade para a camada de saída apresentou um RMSE% de 0,28, coeficiente de correlação de 0,99 e resíduos entre -1 até 0% (figura 15). O resultado da análise global de sensibilidade em ordem decrescente de importância foi: AV2; L_{HH}; L_{VH}; AV3; L_{VV}; AV4; L_{HV}; AV1.

Gama et al. (2010), realizou um estudo em Pindamonhangaba, SP, em um povoamento de *Eucalyptus saligna* com aproximadamente seis anos de idade, onde foi estimado o volume por regressão linear, com dados de alturas obtidas por interferometria entre as bandas P e X, e os coeficientes de retroespalhamento P_{HH}; P_{HV}; P_{VV} e P_{VH}. Apesar da grande variabilidade existente entre as parcelas, devido principalmente à variabilidade genética no plantio, os autores encontraram valores de coeficiente de determinação igual 0,83 e RMSE de 33,56 m³/ha ou 10,55% quando comparado com o maior volume observado.

Tais resultados foram similares aos obtidos utilizando as polarimetrias do sensor PALSAR e inferiores às estimativas obtidas com os sensores PALSAR e AVNIR-2. No

entanto, o reflorestamento aqui estudado é bastante homogêneo, com coeficiente de variação de 12% dos volumes observados.

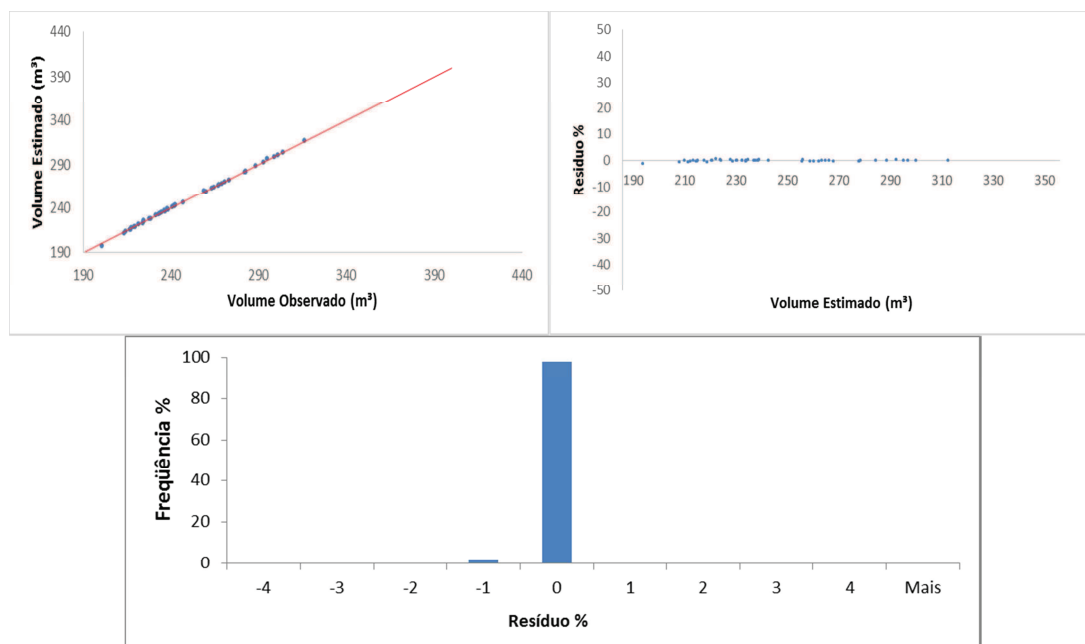


Figura 15 - Gráficos de resíduos utilizando os sensores AVNIR-2 e PALSAR para estimar volume.

4.3.2. Estimativas de biomassa com 5.000 redes neurais

Para estimar a biomassa em função das quatro bandas do sensor AVNIR-2, com as mesmas parcelas utilizadas anteriormente, selecionou-se uma rede neural MLP 4-5-1 com função de ativação tangente hiperbólica para a camada oculta e logística para a camada de saída, obtendo um RMSE% de 5,17, coeficiente de correlação de 0,92 e resíduos entre -8 até 20% (Figura 16). O resultado da análise global de sensibilidade em ordem decrescente de importância foi: AV2; AV4; AV3; AV1.

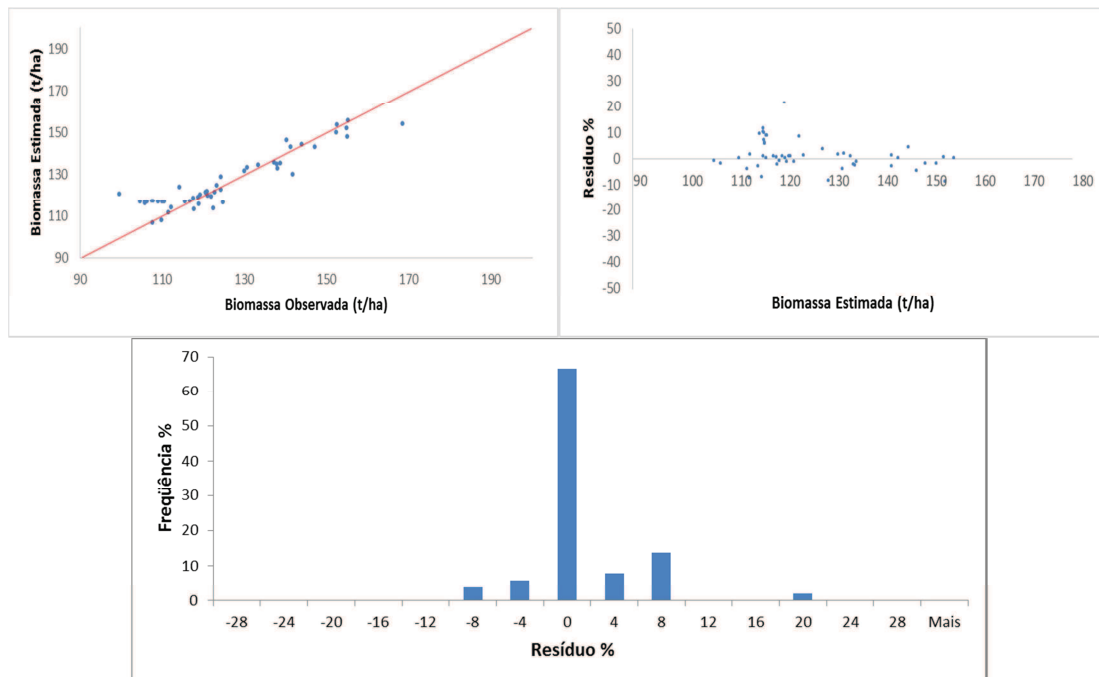


Figura 16 - Gráficos de resíduos utilizando o sensor AVNIR-2 para estimar biomassa.

Para estimar a biomassa em função das quatro bandas do sensor PALSAR, com as mesmas parcelas utilizadas anteriormente, selecionou-se uma rede neural MLP 4-4-1 com função de ativação tangente hiperbólica para a camada oculta e logística para a camada de saída. Os resultados mostraram um RMSE% de 8,93, coeficiente de correlação de 0,72 e resíduos entre -12 e 20% (Figura 17). O resultado da análise global de sensibilidade em ordem decrescente de importância foi: L_{VV} ; L_{HH} ; L_{VH} ; L_{HV} .

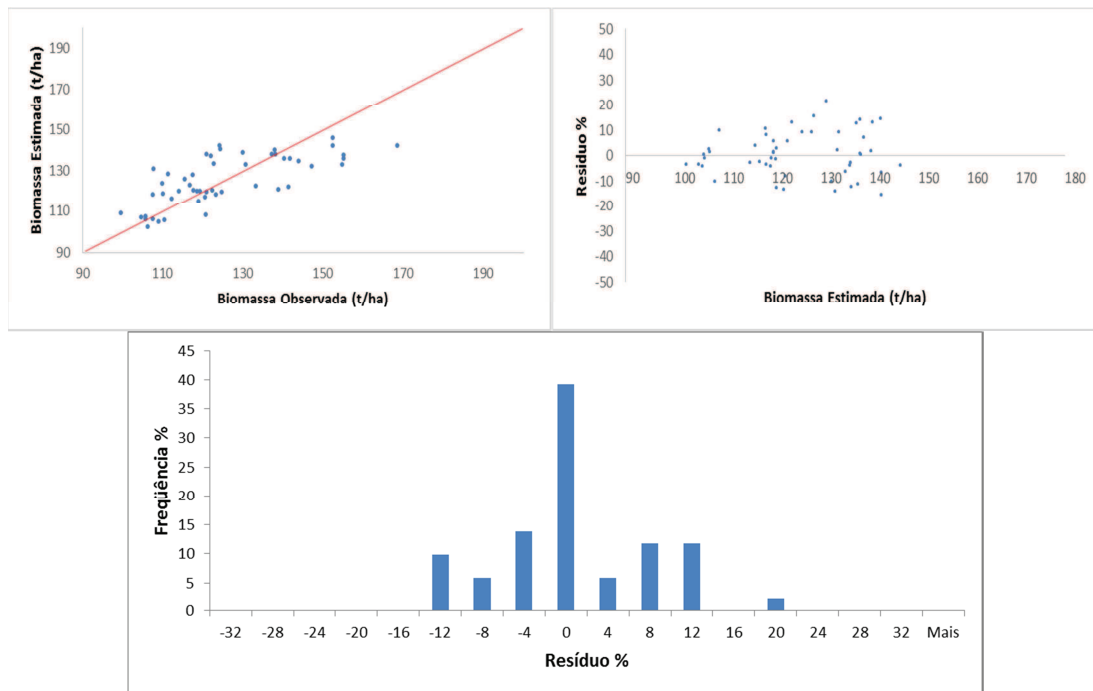


Figura 17 - Gráficos de resíduos utilizando o sensor PALSAR para estimar biomassa.

O melhor resultado para estimar biomassa foi obtido utilizando os sensores AVNIR e PALSAR juntos. A rede neural MLP 8-3-1 com função de ativação tangente hiperbólica para a camada oculta e logística para a camada de saída apresentou um RMSE% de 2,87, coeficiente de correlação de 0,97 e resíduos entre -8 até 4% (Figura 18). O resultado da análise global de sensibilidade em ordem decrescente de importância foi: AV1; L_{VH}; AV3; AV4; L_{VV}; L_{HV}; AV2; L_{HH}.

Gama et al. (2010) encontrou para o mesmo povoamento de *Eucalyptus saligna* citado anteriormente, estimativas de biomassa com coeficiente de determinação de 0,86 e RMSE de 15,65 t/ha ou 10,38% quando comparado com o maior valor de biomassa observado. Estes resultados também foram similares aos obtidos com as polarimetrias do sensor PALSAR. Sendo que foi observado um coeficiente de variação de 13% para os dados de biomassa medidos em campo.

Santos et al. (2012), também usou os dados das bandas X e P, para calcular a altura por interferometria, e o índice CSI na banda P para estimar a biomassa em um plantio de eucalipto na região do vale do rio Paraíba no estado de São Paulo. O resultado foi um erro quadrático de 20,49% quando comparado com valor médio de biomassa e 10,38% quando comparado com o valor máximo de biomassa.

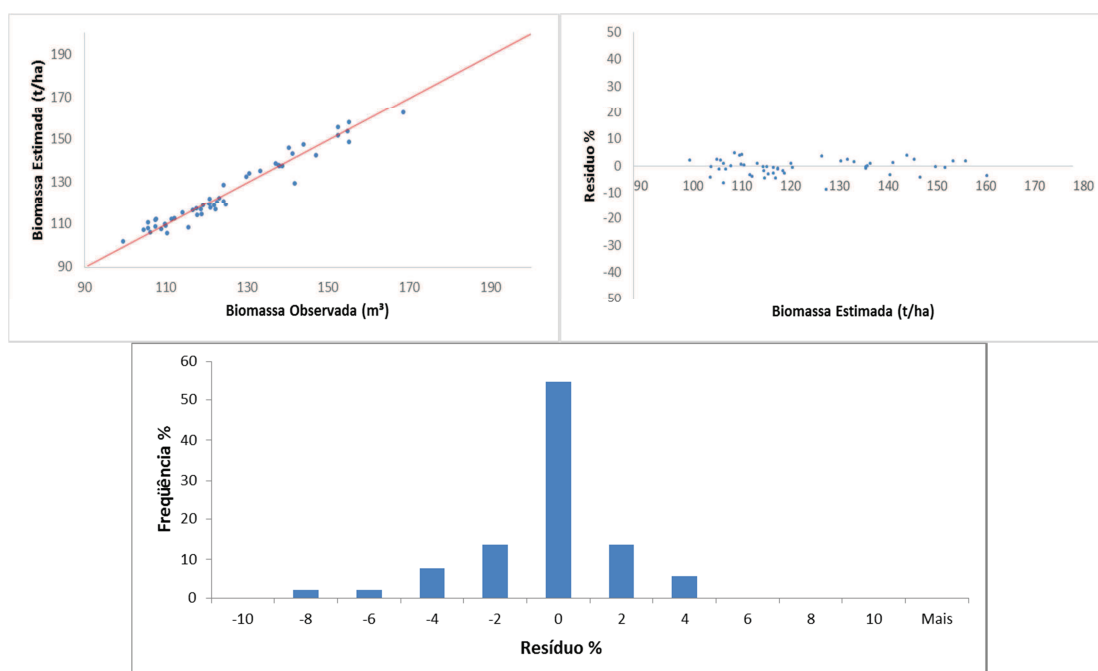


Figura 18 - Gráficos de resíduos utilizando os sensores AVNIR-2 e PALSAR para estimar biomassa.

4.4. Estimativas de volume e biomassa variando o número de parcelas para treinamento da rede

Os melhores ajustes foram obtidos com os dados provenientes dos dois sensores e utilizando 104 parcelas para treinamento. No entanto, como a obtenção de dados de campo sempre está atrelada a custos, analisou-se a capacidade das redes neurais estimarem o volume e a biomassa com menores quantidades de parcelas para treinamento.

Inicialmente, as análises foram feitas para as estimativas do volume. Foram selecionadas aleatoriamente 84 parcelas. A rede neural escolhida foi uma MLP 8-4-1 com função de ativação tangente hiperbólica para a camada oculta e identidade para a camada de saída. O resultado apresentou uma ligeira queda de precisão quando observada a distribuição dos resíduos, que se encontram no intervalo de -1 a 2%, com RMSE% de 0,81 e coeficiente de correlação de 0,99 (Figura 19). O resultado da análise global de sensibilidade em ordem decrescente de importância foi: AV2; L_{HV}; AV1; AV3; AV4; L_{HH}; L_{VH}; L_{VV}.

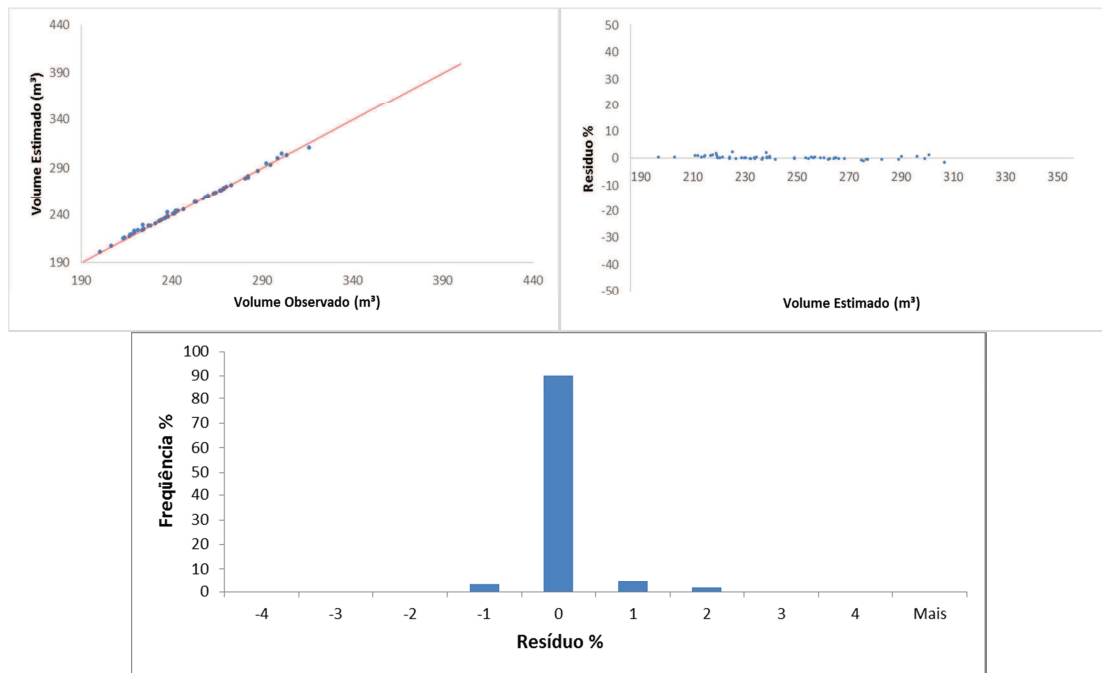


Figura 19 - Gráficos de resíduos do volume utilizando 84 parcelas para treinamento.

Ao se utilizar 62 parcelas, selecionadas aleatoriamente para treinamento, foi escolhida uma rede MLP 8-4-1 com função de ativação tangente hiperbólica para a camada oculta e logística para a camada de saída. Foi observado um aumento na dispersão dos resíduos, variando entre -10 a 12% neste caso. Com isso, também foi observado um aumento do RMSE% para 2,18 e apenas um pequeno declínio no valor do coeficiente de correlação para 0,98 (Figura 20). O resultado da análise global de sensibilidade em ordem decrescente de importância foi: AV2; AV1; L_{VH}; L_{HV}; L_{HH}; AV3; AV4; L_{VV}.

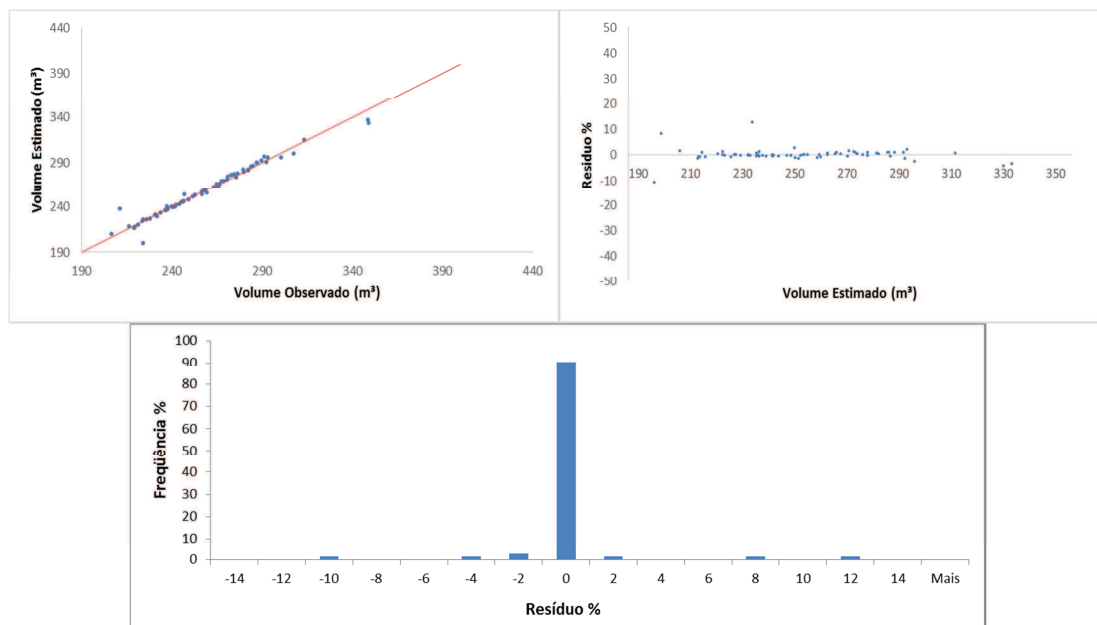


Figura 20 - Gráficos de resíduos do volume utilizando 62 parcelas para treinamento.

Ao se utilizar 42 parcelas, selecionadas aleatoriamente para treinamento, foi escolhida uma rede MLP 8-4-1 com função de ativação tangente hiperbólica para a camada oculta e identidade para a camada de saída. Foi observada uma queda na dispersão dos resíduos em relação à utilização de 62 parcelas, neste caso variando entre -2 a 8%. Com isso, também foi observado uma diminuição do RMSE% para 1,65, porém o valor do coeficiente de correlação de 0,98 se manteve o mesmo (Figura 21). Esse resultado superior em relação à utilização de 62 parcelas pode ter ocorrido por causa das parcelas utilizadas neste treinamento não serem as mesmas daquelas utilizadas anteriormente. O resultado da análise global de sensibilidade em ordem decrescente de importância foi: AV1; L_{VV}; L_{VH}; L_{HH}; AV4; AV3; AV2; L_{HV}.

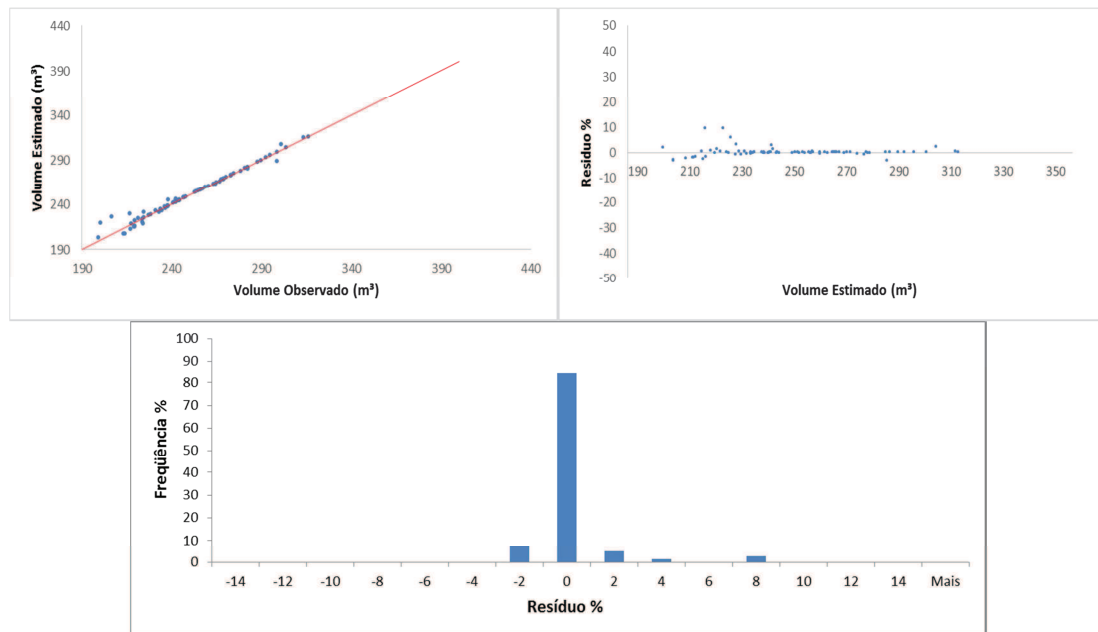


Figura 21 - Gráficos de resíduos do volume utilizando 42 parcelas para treinamento.

Ao se utilizar 22 parcelas, selecionadas aleatoriamente para treinamento, foi escolhida uma rede MLP 8-8-1 com função de ativação tangente hiperbólica para a camada oculta e identidade para a camada de saída. Foi observado um aumento na dispersão dos resíduos, variando entre -14 a 12% neste caso. Com isso, também foi observado um aumento do RMSE% para 6,43 e apenas uma queda no valor do coeficiente de correlação para 0,81. Além disso, foi observada uma tendência de subestimar os maiores valores de volume (Figura 22). Ressalta-se que neste caso foi utilizada a maior quantidade de parcelas para validação.

As estimativas de volume utilizando 84, 62, 42 e 22 parcelas foram próximas daquela obtida utilizando 104 parcelas, porém a estimativa realizada utilizando 22 parcelas para treinamento apresentou uma tendência de subestimar o volume para valores altos (Figura 22).

O resultado da análise global de sensibilidade em ordem decrescente de importância: L_{VH} ; L_{VV} ; L_{HH} ; L_{HV} ; AV_4 ; AV_2 ; AV_3 ; AV_1 .

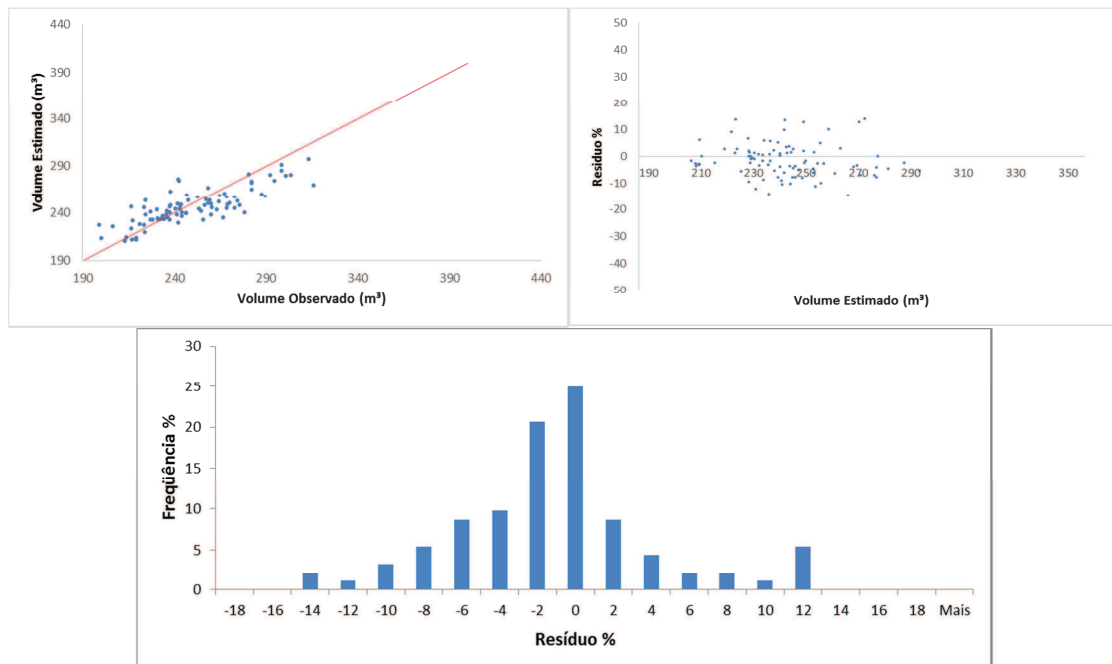


Figura 22- Gráficos de resíduos do volume utilizando 22 parcelas para treinamento.

Ao se utilizar 84 parcelas, selecionadas aleatoriamente para estimar a biomassa, foi escolhida uma rede MLP 8-3-1 com função de ativação logística para a camada oculta e logística para a camada de saída. Em relação à estimativa obtida com 104 parcelas, o resultado apresentou uma ligeira queda de precisão, quando observada a distribuição dos resíduos, que se encontram no intervalo de -8 a 10%. Com isso, foi observado que o RMSE% aumentou para 3,04, porém o coeficiente de correlação diminui apenas de 0,97 para 0,96 (Figura 23). O resultado da análise global de sensibilidade em ordem decrescente de importância foi: AV2; L_{VH}; L_{HH}; L_{VV}; AV3; AV4; AV1; L_{HV}.

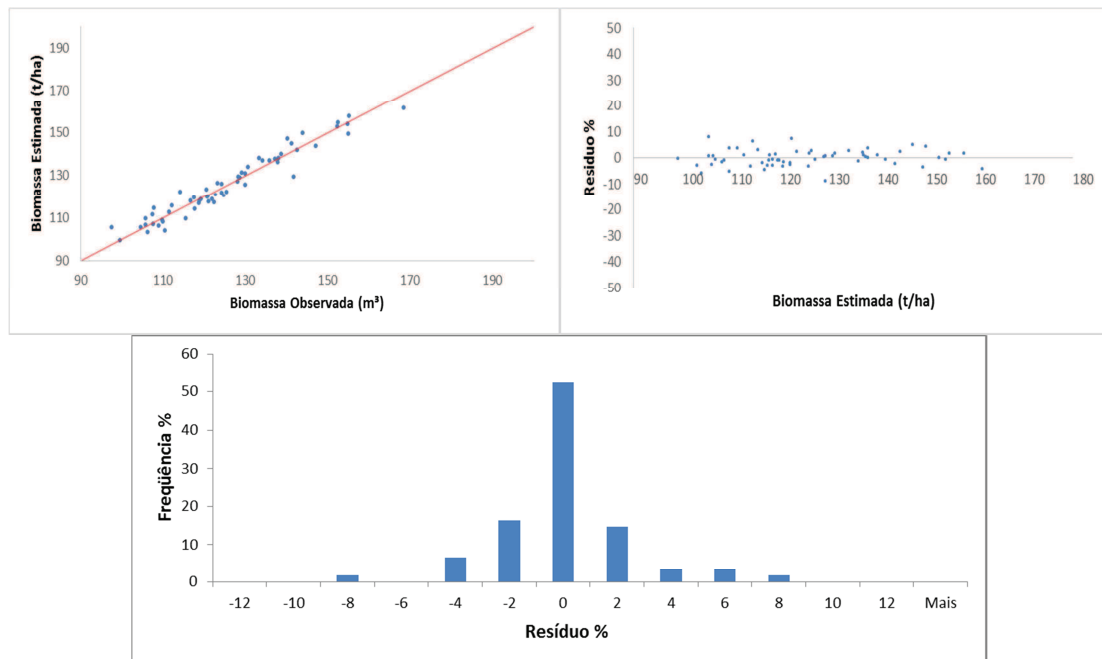


Figura 23-Gráficos de resíduos da biomassa utilizando 84 parcelas para treinamento.

Ao se utilizar 62 parcelas, selecionadas aleatoriamente para estimar a biomassa, foi escolhida uma rede MLP 8-2-1 com função de ativação tangente hiperbólica para a camada oculta e identidade para a camada de saída. Foi observada uma queda na dispersão dos resíduos em relação à utilização de 84 parcelas, agora variando entre -12 a 20%. Com isso, também foi observado um aumento do RMSE% para 5,63 e uma diminuição do valor do coeficiente de 0,96 para 0,88 (Figura 24). O resultado da análise global de sensibilidade em ordem decrescente de importância foi: AV2; L_{VV}; AV3; AV4; L_{VH}; L_{HH}; AV1; L_{HV}.

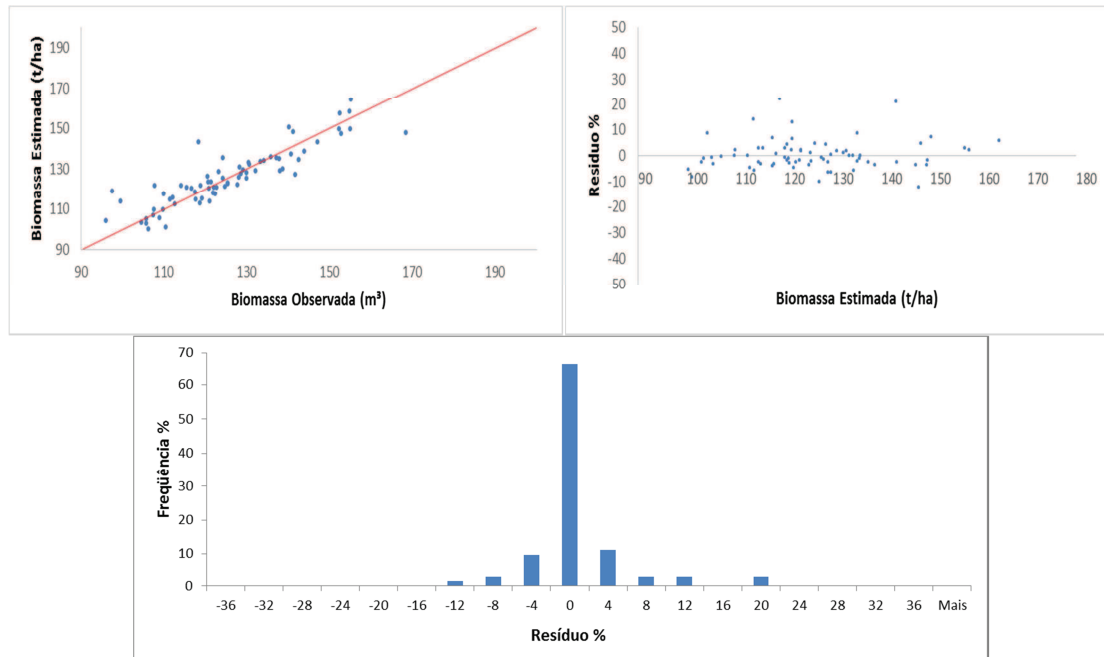


Figura 24- Gráficos de resíduos da biomassa utilizando 62 parcelas para treinamento.

Ao se utilizar 42 parcelas, selecionadas aleatoriamente para estimar biomassa, foi escolhida uma rede MLP 8-2-1 com função de ativação tangente hiperbólica para a camada oculta e tangente hiperbólica para a camada de saída. Foi observada uma queda na dispersão dos resíduos em relação à utilização de 62 parcelas, agora variando entre -32 a 28%. Com isso, também foi observado um aumento do RMSE% para 9,42 e uma diminuição do valor do coeficiente de 0,88 para 0,81 (Figura 25). O resultado da análise global de sensibilidade em ordem decrescente de importância foi: AV2; AV1; AV4; AV3; L_{VV}; L_{HV}; L_{VH}; L_{HH}.

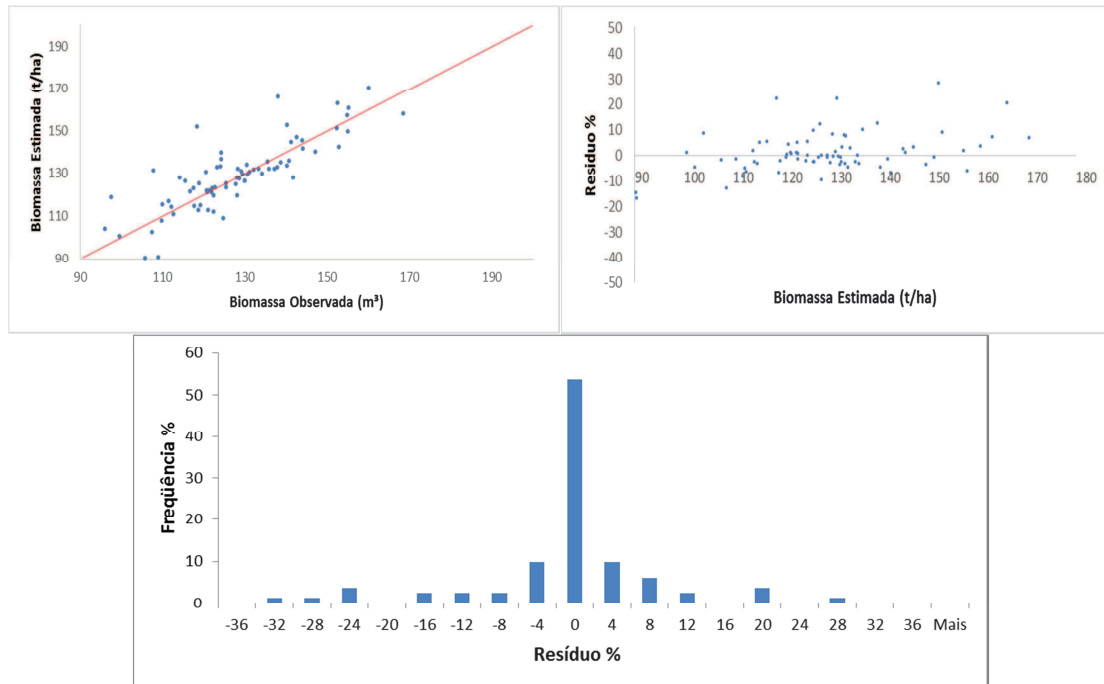


Figura 25- Gráficos de resíduos da biomassa utilizando 42 parcelas para treinamento.

Ao utilizar 22 parcelas, selecionadas aleatoriamente para estimar a biomassa, foi escolhida uma rede MLP 8-6-1 com função de ativação tangente logística para a camada oculta e tangente hiperbólica para a camada de saída. Foi observada uma melhora na dispersão dos resíduos em relação à utilização de 42 parcelas, agora variando entre -16 a 20%. Com isso, também foi observado uma diminuição do RMSE% para 7,35, porém foi observada uma diminuição do valor do coeficiente de 0,81 para 0,79 (Figura 26). O resultado da análise global de sensibilidade em ordem decrescente de importância foi: L_{VH} ; L_{VV} ; L_{HH} ; L_{HV} ; AV4; AV2; AV3; AV1.

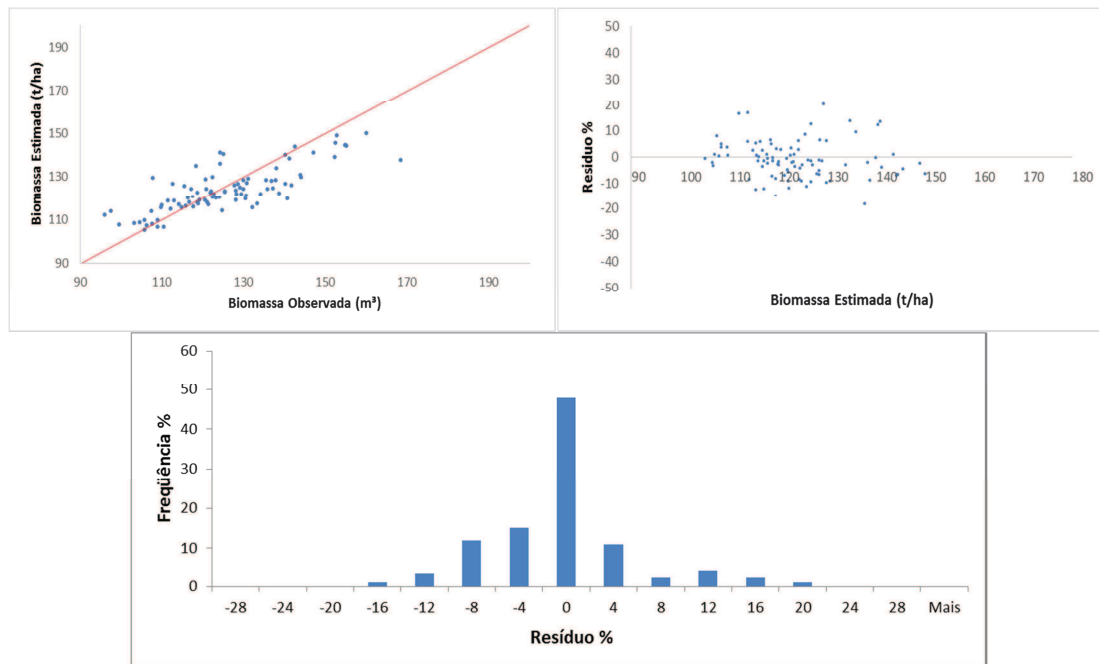


Figura 26- Gráficos de resíduos da biomassa utilizando 22 parcelas para treinamento.

A Tabela 8 contém um resumo dos resultados obtidos para estimar o volume e a biomassa calculados para as parcelas de validação.

As redes neurais apresentaram excelentes resultados, evidenciando a possibilidade de modelar o volume e a biomassa aérea de povoamentos de eucalipto a partir dos dados de sensoriamento remoto.

O resultado obtido para biomassa utilizando somente os dados do sensor PALSAR foi próximo ao obtido por Austin et al. (2003), que obteve um $R^2 = 0,70$ para biomassa total acima do solo em um povoamento de eucalipto na Austrália, modelando parcelas de campo com dados provenientes do radar JERS-1 SAR. Le Toan et al. (1992) realizou um estudo para estimar biomassa em povoamento de pinus no sudoeste da França com dados de radar e encontrou um coeficiente de determinação de 0,73.

Tabela 8 – Redes neurais selecionadas para estimar o volume e a biomassa

Variável	Sensor	Nº de parcelas para treinamento	Rede Neural	RMSE%	R
Volume	AVNIR-2	104	4-7-1	3,36	0,96
Volume	PALSAR	104	4-10-1	7,98	0,72
Volume	AVNIR-2 e PALSAR	104	8-7-1	0,3	0,99
Volume	AVNIR-2 e PALSAR	84	8-4-1	0,81	0,99
Volume	AVNIR-2 e PALSAR	62	8-4-1	2,2	0,98
Volume	AVNIR-2 e PALSAR	42	8-4-1	1,92	0,98
Volume	AVNIR-2 e PALSAR	22	8-8-1	8,01	0,81
Biomassa Aérea	AVNIR-2	104	4-5-1	4,94	0,92
Biomassa Aérea	PALSAR	104	4-4-1	8,87	0,72
Biomassa Aérea	AVNIR-2 e PALSAR	104	8-3-1	2,87	0,97
Biomassa Aérea	AVNIR-2 e PALSAR	84	8-3-1	3,15	0,96
Biomassa Aérea	AVNIR-2 e PALSAR	62	8-2-1	5,9	0,88
Biomassa Aérea	AVNIR-2 e PALSAR	42	8-2-1	9,03	0,81
Biomassa Aérea	AVNIR-2 e PALSAR	22	8-6-1	8,89	0,79

Em seu estudo, Baghdadi et al. (2014) sugeriram que a integração de dados provenientes do sensor PALSAR com outros dados poderiam aumentar a acurácia das estimativas. O estudo realizado pelos autores em plantios de eucalipto no estado de São Paulo utilizou dados de inventário com informações de biomassa e idade do plantio, dados do sensor PALSAR e modelagem feita pela técnica de regressão Random Forest. Com isso, os autores obtiveram um RMSE de 46,7 t/ha quando utilizaram somente os

dados do sensor PALSAR, porém ao utilizar os dados de idade, o RMSE diminui para 18,9 t/ha.

Comparando com os resultados obtidos por Oliveira (2011), as estimativas obtidas pelas redes neurais artificiais foram superiores às obtidas pela análise de regressão. O modelo de regressão proposto apresentou um $R^2= 0,71$ para a biomassa e um $R^2= 0,69$ para o volume, enquanto a rede neural artificial apresentou coeficientes de determinação superiores a estes com apenas 10% dos dados utilizados para o treinamento. A Tabela 9 apresenta os resultados obtidos pela análise global de sensibilidade.

Tabela 9 - Análise global de sensibilidade

Rede Neural	Ordem decrescente de importância das variáveis independentes							
4-7-1	AV2	AV4	AV1	AV3				
4-10-1	L _{VV}	L _{VH}	L _{HH}	L _{HV}				
8-7-1	AV2	L _{HH}	L _{VH}	AV3	L _{VV}	AV4	L _{HV}	AV1
8-4-1	AV2	L _{VV}	AV4	AV1	L _{VH}	L _{HH}	L _{HV}	AV3
8-4-1	AV2	AV1	L _{VH}	L _{HV}	L _{HH}	AV3	AV4	L _{VV}
8-4-1	AV1	L _{VV}	L _{VH}	L _{HH}	AV4	AV3	AV2	L _{HV}
8-8-1	L _{VH}	L _{VV}	L _{HH}	L _{HV}	AV4	AV2	AV3	AV1
4-5-1	AV2	AV4	AV3	AV1				
4-4-1	L _{VV}	L _{HH}	L _{VH}	L _{HV}				
8-3-1	AV1	L _{VH}	AV3	AV4	L _{VV}	L _{HV}	AV2	L _{HH}
8-3-1	AV2	L _{VH}	L _{HH}	L _{VV}	AV3	AV4	AV1	L _{HV}
8-2-1	AV2	L _{VV}	AV3	AV4	L _{VH}	L _{HH}	AV1	L _{HV}
8-2-1	AV2	AV1	AV4	AV3	L _{VV}	L _{HV}	L _{VH}	L _{HH}
8-6-1	L _{VH}	L _{VV}	L _{HH}	L _{HV}	AV4	AV2	AV3	AV1

As variáveis mais importantes em ordem decrescente foram: AV2; L_{VH}; L_{VV}; AV4; L_{HH}; AV1; AV3; L_{HV}. Esta análise foi feita pela ponderação da frequência de cada variável na posição de importância, sendo atribuído peso oito para a posição mais importante e diminuindo até o peso zero para a posição menos importante.

As polarizações L_{VV} e L_{HH} apresentaram pequena diferença no nível de importância obtido pela análise de sensibilidade global, enquanto a diferença entre as polarizações L_{VH} e L_{HV} foram maiores. A refletância na banda AV2 apresentou maior importância do que as demais do sensor AVNIR-2, sendo estas últimas similares no

nível de importância. Todavia, não foi possível determinar quais variáveis são mais influentes, visto que uma variável pode ser importante em uma rede e em outra não ser.

5. CONCLUSÕES

A integração de dados provenientes dos sensores remotos AVNIR-2 e PALSAR resulta em maior eficiência na estimação de povoamentos de eucalipto empregando redes neurais.

As quatro bandas do sensor AVNIR-2 e as quatro polarizações do sensor PALSAR foram importantes para estimar biomassa e volume de povoamentos de eucalipto com o emprego de redes neurais.

Apenas um pequeno número de parcelas foi suficiente para treinar as redes neurais artificiais visando estimar volume e biomassa. Além disso, a rápida convergência obtida pelo algoritmo BFGS permitiu uma análise abrangente dos dados.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- AUSTIN, J.; MACKEY, B.; VAN NIEL, K. Estimating forest biomass using satellite radar: An exploratory study in a temperate Australian *Eucalyptus* forest. *Forest Ecology and Management*, v. 176, n. 1, p. 757-583, 2003.
- BALZTER H. Forest mapping and monitoring with interferometric synthetic aperture radar (InSAR). *Progress in Physical Geography*, v. 25, n. 2, p. 159-177, 2001.
- BARBOSA, J. M.; BROADBENT, E. N.; BITENCOURT, M. D. Remote sensing of aboveground biomass in tropical secondary forests: A review. *International Journal of Forestry Research*, v. 1, 14 p., 2014.
- BLACKARD, J. A.; DEAN, D. J. Comparative accuracies of artificial neural networks and discriminant analysis in predicting forest cover types from cartographic variables. *Computers and Electronics in Agriculture*, v. 24, n. 3, p. 131-151, 1999.
- BAGHDADI, N.; MAIRE, G.; BAILLY, J.; OSÉ, K.; NOUVELLON, Y.; ZRIBI, M.; LEMOS, C.; HAKAMADA, R. Estimation of Eucalyptus plantations aboveground biomass in Brazil using ALOS/PALSAR L-band data. *IEEE Geoscience and Remote Sensing Symposium (IGARSS)*, v. 1, p. 721-724, 2014.
- BASSO, B.; CAMMARANO, D.; VITA, P. Remotely sensed vegetation indices: Theory and applications for crop management. *Rivista Italiana di Agrometeorologia*, v. 1, p. 36-53, 2004.
- BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. *Revista Árvore*, v. 37, n. 4, p. 639-645, 2013.
- BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. Configuração de redes neurais artificiais para estimação do volume de árvores. *Revista Ciência da Madeira*, v. 5, n. 1, p. 58-67, 2014.
- BINOTI, M. L. M. S.; LEITE, H. G.; BINOTI, D. H. B.; GLERIANI, J. M. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. *Cerne*, v. 21, n. 1, p. 97-105, 2015.
- BROWN, S. L.; SCHROEDER, P.; KERN, J. S. Spatial distribution of biomass in forests of the eastern USA. *Forest Ecology and Management*, v. 123, n. 1, p. 81-90, 1999.
- BROWN, S.; Measuring carbon in forests: current status and future challenges. *Environmental Pollution*, v. 116, n. 3, p. 363-372, 2002.
- CAMPBELL, J. B. *Introduction to Remote Sensing*. 3.ed New York: The Guildford Press, Inc., 621 p. 2002

CARREIRAS, J. M. B.; VASCONCELOS, M. J.; LUCAS, R. M. Understanding the relationship between aboveground biomass and ALOS PALSAR data in the forests of Guinea-Bissau (West Africa). *Remote Sensing of Environment*, v. 121 p. 426-442, 2012.

CASTAÑO-SANTAMARÍA, J.; CRECENTE-CAMPO, F.; FERNÁNDEZ-MARTÍNEZ, J. L.; BARRIO-ANTA, M.; OBESO, J. R. Tree height prediction approaches for uneven-aged beech forests in northwestern Spain. *Forest Ecology and Management*, v. 307, p. 63-73, 2013.

CHAMBERS, J. Q.; ASNER, G. P.; MORTON, D. C.; LIANA, O. A.; SAATCHI, S. S.; ESPÍRITO-SANTO, F. D. B.; PALACE, M.; SOUZA, C. Regional ecosystem structure and function: ecological insights from remote sensing of tropical forests. *TRENDS in Ecology and Evolution*, v. 22, n. 8, o. 414-423, 2007.

COOPS, N. C. Eucalypt forest structure and synthetic aperture radar backscatter: a theoretical analysis. *Trees*, v. 16, n. 1, p. 28-46, 2001.

CORTÉS, L.; HERNÁNDEZ, J.; VALENCIA, D.; CORVALÁN, P. Estimation of above-ground forest biomass using Landsat ETM+, Aster GDEM and Lidar. *Forest Research*, v. 3 n. 2, 2014.

DIAMANTOPOULOU, M. J. Artificial neural networks as an alternative tool in pine bark volume estimation. *Computers and Electronics in Agriculture*, v. 48, n. 3, p. 235-244, 2005.

DUBE, T.; MUTANGA, O. Evaluating the utility of the médium-spatial resolution Landsat 8 multispectral sensor in quantifying aboveground biomass in uMgeni catchment, South Africa. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 101, p. 36-46, 2015.

ELACHI, C.; ZYL, J. *Introduction to the physics and techniques of Remote Sensing*. 2.ed. New York: John Wiley and Sons, Inc., 559 p. 2006.

ENGLHART, S.; KEUCK, V.; SIEGERT F. Aboveground biomass retrieval in tropical forests — The potential of combined X- and L-band SAR data use. *Remote Sensing of Environment*, v. 115, n. 5, p. 1260-1271, 2011.

FERRAZ, A. S. *Estimação dos estoques de biomassa e carbono na parte aérea de um fragmento de floresta estacional semidecidual por meio de imagens de satélite IKONOS II*. 2012. 103 f. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, 2012.

FILHO, C. R. S.; AUGUSTO, V.; OLIVEIRA, W. J.; LAMMOGLIA, T. Detecção de exsudações de hidrocarbonetos por geobotânica e sensoriamento remoto multi-temporal: estudo de caso no Remanso do Fogo (MG). *Revista Brasileira de Geociências*, v. 38, n. 2, p. 228-243, 2008.

FOODY, G. M.; CUTLER, M. E.; MCMORROW, J.; PELZ, D.; TANGKI, H.; BOYD, D. S.; DOUGLAS, I. Predictive relations of tropical forest biomass from Landsat TM

data and their transferability between regions. *Global Ecology and Biogeography*, v. 10, p. 379-387, 2001.

FOODY G. M., CUTLER M. E. J. Mapping the species richness and composition of tropical forests from remotely sensed data with neural networks. *Ecological Modeling*, v. 195, p. 37-42, 2006.

FRATE F. D., SOLIMINI D. On Neural Network Algorithms for Retrieving Forest Biomass From SAR Data. *IEEE Transactions on Geoscience and Remote Sensing*, v. 42, n. 1, p. 24-34, 2004.

GAMA F. F., SANTOS J. R., MURA J. C. Eucalyptus Biomass and Volume Estimation Using Interferometric and Polarimetric SAR Data. *Remote Sensing*, v. 2, n. 4, p. 939-956, 2010.

GATES, D. M.; TANTRAPORN, W. The reflectivity of deciduous trees and herbaceous plants in the infrared to 25 microns. *Science*, v. 115, n. 2997, p. 613-616, 1952.

HECHT-NIELSEN R. Theory of the Backpropagation Neural Network. *IEEE International Joint Conference on Neural Networks*, v. 1, p. 593-605, 1989.

HOPFIELD, J. J. Artificial neural networks. *IEEE Circuits and Devices Magazine*, v. 4, n. 5, p. 3-10, 1988.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. *Mapa de solos do Brasil*. Rio de Janeiro: Ministério do Planejamento, Orçamento e Gestão, 2001. 1 mapa, color., Escala 1: 5.000.000

IMHOFF, M. L. A theoretical analysis of the effect of forest structure on Synthetic Aperture Radar backscatter and the remote sensing of biomass. *IEEE Transactions on Geoscience and Remote Sensing*, v. 33, n. 2, p. 341-352, 1995.

JAXA. Agência de Eploração Aeroespacial Japones. *PALSAR Reference Guide*. 2012. Disponível em: < <http://gds.palsar.ersdac.jpspacesystems.or.jp/e/guide/> > Acesso em: 28/01/2015.

KOZAK, A.; MUNRO, D. D.; SMITH, J. H. G. Taper functions and their application in forest inventory. *The Forestry Chronicle*, v. 45, n. 4, p. 278-283, 1969.

LEBOEUF, A.; BEAUDOIN, A.; FOURNIER, R. A.; GUINDON, L.; LUTHER, J. E.; LAMBERT, M. C. A shadow fraction method for mapping biomass of northern boreal black spruce forests using Quickbird imagery. *Remote Sensing of Environment*, v. 110, n. 4, p. 488-500, 2007.

LEITE, H. G.; SILVA, M. L. M.; BINOTI, D. H. B. FARDIN, L.; TAKIZAWA, F. H. Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn. Trees using artificial neural networks. *European Journal of Forest Research*, v. 130, n. 2, p. 263-269, 2011.

LE TOAN, T.; BEAUDOIN, J. R.; GUYON, D. Relating forest biomass to SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, v. 30, n. 2, p. 403-411, 1992.

LE TOAN, T.; PICARD, G.; MARTINEZ, J.; MELON, P.; DAVIDSON, M. On the relationships between radar measurements and forest structure and biomass. *3rd International Symposium Retrieval of Bio- and Geophysical Parameters from SAR data for land Applications*, Sheffield, Uk: ESA (ESA SP-475), p. 3-12. 2002.

LILLESAND, D. G.; RANSON, K. J. Forestry applications using imaging radar. In: *Principles and Applications of Imaging Radar*. New York: John Wiley and Sons, p. 756, 2007.

LU D. Aboveground biomass estimation using Landsat TM data in the Brazilian Amazon. *International Journal of Remote Sensing*, v. 26, n. 12, p. 1297-1328, 2005.

LU D. The potential and challenge of remote sensing-based biomass estimation. *International Journal of Remote Sensing*, v. 27, n. 12, p. 1297-1328, 2006.

LUCAS, R.; ARMSTON, J.; FAIRFAX, R.; FENSHAM, R.; ACCAD, ARNOM.; CARREIRAS, J.; KELLEY, J.; BUNTING, P.; CLEWLEY, D.; BRAY, S.; METCALFE, D.; DWYER, J.; BOWEN, M.; EYRE, T.; LAIDLAW, M.; SHIMADA, M. An evaluation of the ALOS PALSAR L-band backscatter - above ground biomass relationship Queensland, Australia: Impacts of surface moisture condition and vegetation structure. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 3, n. 4, p. 576-593, 2010.

LUCAS, R. M.; MILNE, A. K. Synthetic Aperture Radar for woodland biomass estimation in Australia: An overview. *International Geoscience and Remote Sensing Symposium*. v. 3, p. 1421-1423, 2001.

LUTHER, J. E.; FOURNIER, R. A.; PIERCEY, D. E.; GUINDON, L.; HALL, R. J. Biomass mapping using forest type and structure derived from Landsat TM imagery. *International Journal of Applied Earth Observation and Geoinformation*, v. 8, n. 3, p. 173-187, 2006.

MAS, J. F., PUIG H., PALACIO J. L., SOSA-LO'PEZ A. Modelling deforestation using GIS and artificial neural networks. *Environmental Modelling & Software*, v. 19, n. 5, p. 461-471, 2004.

MCROBERTS, R. E.; TOMPPO, E. O. Remote sensing support for national forest inventories. *Remote sensing of Environmen,t* v. 110, n. 4, p. 412-419, 2007.

MUUKKONEN, P.; HEISKANEN J. Estimating biomass for boreal forests using ASTER satellite data combined with standwise forest inventory data. *Remote Sensing of Environment*, v. 99, n. 4, p. 434-447, 2005.

OLIVEIRA, F. S. *Uso de Imagens de Satélite Alos para Estimativa de Parâmetros Dendrométricos de Plantios de Eucalipto*. 2011. 159 f. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, MG, 2011.

OZÇELIK, R.; DIAMANTOPOULOU, M. J.; CRECENTE-CAMPO F.; ELER, U. Estimating Crimean Juniper tree height using nonlinear regression and artificial neural network models. *Forest Ecology and Management*, v. 306, p. 52-60, 2013.

RABUS, B.; EINEDER, M.; ROTH, A.; BAMBLER, R. The shuttle radar topography mission – a new class of digital elevation models acquired by spaceborne radar. *ISPRS Journal of Photogrammetry & Remote Sensing*, v. 57, n. 4, p. 241-262, 2003.

REESE, H.; NILSSON, M.; SANDSTROM, P.; OLSSON, H. Applications using estimates of forest parameters derived from satellite and forest inventory data. *Computers and Electronics in Agriculture*, v. 37, n. 1, p. 37-55, 2002.

ROSENQVIST, A.; MILNE, A.; LUCAS, R.; IMHOFF, M.; DOBSON, C. A review of remote sensing technology in support of the Kyoto Protocol. *Environmental Science & Policy*, v. 6, n. 5, p. 441-455, 2003.

RYU, S. R.; CHEN, J.; CROW, T. T.; SAUNDERS, S. C. Available fuel dynamics in nine contrasting forest ecosystems in north America. *Environmental Management*, v. 33, n. 1, p. 87-107, 2004.

SANTOS, J. R.; GAMA, F. F.; NARVAES, I. S.; MURA J. C. Forest biomass modelling by polarimetric and interferometric SAR data: The Brazilian scientific missions. In: *32nd EARSeL Symposium: Advances in Geosciences*, p. 244-250, 2012.

SARKER, L. R.; NICHOL J. E. Improved forest biomass estimates using ALOS AVNIR-2 texture indices. *Remote Sensing of Environment*, v.115, n. 4, p. 968-977, 2011.

SHUMACHER, F. X.; HALL, F. S. Logarithmic expression of timber-tree volume. *Journal of Agricultural Research*, v. 47, n. 9, p. 719-734, 1933.

SILVA, M. L. M.; BINOTI, D. H. B.; GLERIANI, J. M.; LEITE, H. G. Ajuste do modelo de Shumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto. *Revista Árvore*, v. 33, n. 6, p. 1133-1139, 2009.

SOENEN, S. A.; PEDDLE, D. R.; HALL, R. J.; COBURN, C. A.; HALL, F. G. Estimating aboveground forest biomass from canopy reflectance model inversion in mountainous terrain. *Remote Sensing of Environment*, v. 114, n. 7, p. 1325-1337, 2010.

STATHAKIS, D. How many hidden layers and nodes? *International Journal of Remote Sensing*, v. 30, n. 8, p. 2133-2147, 2009.

STATSOFT, Inc. *Statistica* (data analysis software system), version 12. Disponível em: <<http://www.statsoft.com>>. Acesso em: 28 jan. 2015.

TETKO, I. V.; LIVINGSTONE, D. J.; LUIK, A. Neural Network Studies. 1. Comparison of Overfitting and Overtraining. *Journal of Chemical Information and Computer Sciences*, v. 35, p. 826-833, 1995.

VIANA, H.; ARANHA, J.; LOPES, D.; COHEN, W. B. Estimation of crown biomass of *Pinus pinaster* stands and shrubland above-ground biomass using forest inventory data, remotely sensed imagery and spatial prediction models. *Ecological Modelling*, v. 226, p. 22-35, 2012.

WANG, J. R.; ZHONG, A. L.; COMEAU, P.; TSZE, M.; KIMMINS, J. P. Aboveground biomass and nutrient accumulation in an age sequence of aspen (*Populus tremuloides*) stands in the boreal white and black spruce zone, British Columbia. *Forest Ecology and Management*, v. 78, n. 1, p. 127-138, 1995.

WULDER, M. Optical remote sensing techniques for the assessment of forest inventory and biophysical parameters. *Progress in Physical Geography*, v. 22, n. 4, p. 449-476, 1998.

YEGNANARAYANA, B. *Artificial neural networks*. 3.ed. PHI Learning Pvt. Ltd., 461 p. 2006.

ZOLKOS, S. G.; GOETZ, S. J.; DUBAYAH, R. A meta-analysis of terrestrial aboveground biomass estimation using lidar remote sensing. *Remote Sensing of Environment*, v. 128 p. 289-298, 2013.

7. APÊNDICE A

Tabela 10 – Parcelas de estudo

Parcela	Volume (m³/ha)	Biomassa (t/ha)	LHH	LHV	LVV	LVH	AV1	AV2	AV3	AV4
1	206,64	97,57	143,143	130,782	130,886	175,431	63,443	39,244	24,944	58,838
2	216,82	103,20	168,196	139,222	138,327	197,835	60,494	31,274	16,543	20,196
3	224,33	107,58	166,721	138,475	137,646	194,674	64,124	31,743	17,038	22,471
4	258,88	124,20	131,605	120,615	121,694	124,812	65,455	33,901	30,677	32,935
5	224,52	107,71	141,081	128,522	127,747	136,007	64,132	41,106	26,906	67,864
6	253,03	121,39	145,451	125,063	124,317	144,103	65,230	33,536	18,927	31,163
7	234,00	112,26	138,571	137,513	136,769	133,821	60,891	32,347	17,674	25,399
8	237,89	114,13	164,059	137,127	136,416	127,546	60,981	42,498	28,374	74,613
9	235,74	113,14	138,055	124,332	123,480	134,993	64,564	42,274	28,138	73,528
10	235,62	113,08	143,925	137,352	122,578	134,065	60,928	32,448	17,781	25,890
•	•	•	•	•	•	•	•	•	•	•
•	•	•	•	•	•	•	•	•	•	•
•	•	•	•	•	•	•	•	•	•	•
100	288,03	143,89	141,722	124,165	124,560	130,689	62,140	35,722	21,232	99,924
101	273,06	136,41	138,285	125,584	124,814	134,250	66,002	46,160	32,233	92,367
102	257,55	128,66	129,747	122,692	122,936	129,981	61,435	33,818	19,225	32,532
103	341,08	170,55	135,619	122,928	120,752	130,628	68,622	53,242	39,698	126,704
104	271,05	135,53	141,697	131,468	132,726	136,477	65,924	34,662	20,114	36,621
105	300,63	150,33	135,562	129,352	130,056	141,338	67,064	49,030	35,259	106,284
106	244,13	122,07	132,713	126,137	126,078	128,216	61,125	32,980	18,341	28,468
107	228,03	114,02	154,987	130,352	130,479	155,461	60,753	31,974	17,281	23,591
108	276,64	138,33	145,790	127,004	127,205	141,028	66,140	46,532	32,626	38,314
109	282,42	141,31	153,067	126,738	128,791	143,059	66,362	47,134	33,261	97,092
110	213,32	107,00	156,664	126,469	127,317	199,309	63,700	39,939	25,677	62,210
•	•	•	•	•	•	•	•	•	•	•
•	•	•	•	•	•	•	•	•	•	•
•	•	•	•	•	•	•	•	•	•	•
200	216,76	115,54	146,438	127,970	127,575	141,782	63,833	40,298	26,055	63,946
201	287,90	153,46	130,966	118,148	119,063	125,600	62,137	47,705	33,862	99,858
202	265,37	142,16	146,825	128,495	126,748	157,755	61,616	34,307	19,740	34,901
203	265,24	142,09	135,648	124,123	125,791	126,777	65,700	45,345	31,375	88,419
204	268,44	143,81	145,764	126,649	126,465	143,638	61,687	34,499	19,942	35,831
205	272,66	146,07	132,120	123,714	125,832	132,376	61,785	34,762	32,189	37,109
206	264,53	141,71	139,641	124,861	125,845	128,441	65,673	34,254	19,685	34,646