



**MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL RURAL DA AMAZÔNIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS**

**ANDRÉ RICARDO DOS SANTOS PEREIRA**

**USO DE REDES NEURAS ARTIFICIAIS COMO ALTERNATIVA PARA  
ESTIMATIVA VOLUMETRICA NA FLORESTA ESTADUAL DO AMAPÁ**

**Belém-PA  
Julho de 2018**



**MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL RURAL DA AMAZÔNIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS**

**ANDRÉ RICARDO DOS SANTOS PEREIRA**

**USO DE REDES NEURAS ARTIFICIAIS COMO ALTERNATIVA PARA  
ESTIMATIVA VOLUMETRICA NA FLORESTA ESTADUAL DO AMAPÁ**

Dissertação apresentada à Universidade Federal Rural da Amazônia para obtenção do título de Mestre em Ciências Florestais na área de concentração Manejo de Ecossistemas Florestais.

Orientador: D. Phil. José Natalino Macedo Silva

**Belém-PA  
Julho de 2018**


**MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL RURAL DA AMAZÔNIA  
PROGRAMA DE PÓS GRADUAÇÃO EM CIÊNCIAS FLORESTAIS**

**ANDRÉ RICARDO DOS SANTOS PEREIRA**

**USO DE REDES NEURAS ARTIFICIAIS COMO ALTERNATIVA PARA  
ESTIMATIVA VOLUMETRICA NA FLORESTA ESTADUAL DO AMAPÁ**

Exame de dissertação apresentada à Universidade Federal Rural da Amazônia como parte das exigências do Curso de Mestrado em Ciências Florestais, para obtenção do título de **Mestre**.

**BANCA EXAMINADORA**



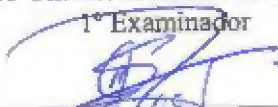
---

PHD. José Natalino Macedo Silva  
Universidade Federal Rural da Amazônia - UFRA  
Presidente



---

Dr. Daniel Henrique Breda Binoti  
Centro Universitário São Camilo-USC  
1º Examinador



---

Dr. Eduardo Saraiva da Rocha  
Universidade Federal Rural da Amazônia-UFRA  
2º Examinador



---

Dr. Moisés Cordeiro Mourão de Oliveira Junior  
Empresa Brasileira de Pesquisa Agropecuária-EMBRAPA  
3º Examinador

**Belém-PA**

**Julho de 2018**

*Ao meu pai, João Batista Pereira (Seu Badé da caçamba amarela)  
A minha mãe Rosilene Machado dos Santos*

**Dedico**

*Ao quarteto mais lindo de mulheres do Amapá: Ana Luiza, Sâmia Borges,  
Rosiane Pereira e Michele Pereira*

**Ofereço**

*A minha Família*

**Agradeço**

## **AGRADECIMENTO**

Agradeço primeiramente a Deus, por confortar meu coração nos momentos difíceis e me oportunizar tantos momentos de felicidade nessa pequena passagem na terra.

Ao meu amado Pai João Batista Pereira (Seu Badé), pelo amor incondicional e por acreditar nos meus sonhos e sempre estar ao meu lado e a sua companheira Mayara;

À minha Mãe Rosilene Machado dos Santos pelo imenso amor e carinho incondicional em todos os momentos da vida;

As minhas Irmãs Ana Luiza, Sâmia Borges, Rosiene Pereira e Michele Pereira pelo amor e carinho;

A minha companheira Carla Helienai, por me apoiar em todos os momentos;

Aos meus amigos de profissão Robson Lima, Marcio Cordeiro e Marcos Almeida por sempre me ajudarem e tirarem as minhas dúvidas;

Ao meu orientador D. Phil. José Natalino Macedo Silva, pela paciência e dedicação na orientação deste trabalho e todos os ensinamentos;

A minha banca examinadora: Daniel Binoti, Eduardo Saraiva e Moises Cordeiro;

Ao PPGCF por me permitir realizar essa pesquisa e conquistar o título de Mestre;

Ao Instituto Estadual de Florestas do Amapá - IEF por ter cedido os dados para pesquisa;

A empresa DAP Florestal por fornecer o software NeuroForest para esse estudo.

Enfim, a todos que tiveram envolvido direta ou indiretamente para o desenvolvimento dessa dissertação, os meus sinceros agradecimentos.

## LISTA DE FIGURAS

<b>Figura 1.</b> Anatomia de um neurônio (Fonte: Nishida, 2007). .....	8
<b>Figura 2.</b> Modelo de um neurônio artificial (Fonte: Haykin, 2001). .....	8
<b>Figura 3.</b> (a) Função de limiar, (b) Função linear, (c) Função sigmóide com parâmetro de inclinação a variável. ....	10
<b>Figura 4.</b> Rede neural com uma única camada (Fonte: Haykin, 1999) .....	11
<b>Figura 5.</b> Rede Neural Feedforward com múltiplas camadas (Fonte: Haykin, 1999)...	12
<b>Figura 6.</b> Localização da Floresta Estadual do Amapá (Fonte: Almeida, 2018).....	13
<b>Figura 7.</b> Localização das (trinta) 30 unidades amostrais onde foram realizadas as coletas na Floresta Estadual do Amapá .....	16
<b>Figura 8.</b> Esquema de cubagem de árvores caídas dividindo a altura comercial em 10 partes (Fonte: Gomes, 2008) .....	17
<b>Figura 9.</b> Distribuição de frequência das árvores amostradas por diâmetro (DAP) na fitofisionomia Floresta de Terra Firme de Baixo Platô .....	18
<b>Figura 10.</b> Distribuição de frequência das árvores amostradas por diâmetro (DAP) na fitofisionomia Floresta de Terra Firme Densa de Submontana .....	18
<b>Figura 11.</b> Distribuição de frequência das árvores amostradas por diâmetro (DAP) na fitofisionomia Transição Cerrado Floresta .....	19
<b>Figura 12.</b> Distribuição dos resíduos em função dos valores preditos, para os cinco modelos ajustados para a fitofisionomia FTFDBP .....	24
<b>Figura 13.</b> Distribuição dos resíduos em função dos valores preditos, para os cinco modelos ajustados para a fitofisionomia FTFSM .....	26
<b>Figura 14.</b> Distribuição dos resíduos em função dos valores preditos, para os cinco modelos ajustados para a fitofisionomia TCF .....	27
<b>Figura 15.</b> Gráfico de distribuição do volume estimado pelo observado $m^3$ da RNA 7 FTFBP .....	29
<b>Figura 16.</b> Gráfico de distribuição do volume estimado pelo observado $m^3$ da RNA 6 FTFSM .....	30
<b>Figura 17.</b> Gráfico de distribuição do volume estimado pelo observado $m^3$ da RNA 2 TCF .....	31
<b>Figura 18.</b> Gráfico de distribuição do volume estimado e observado dos modelos matemáticos selecionados para a FTFBP , FTFSM e TCF com 20% dados de validação .....	33
<b>Figura 19.</b> Gráfico de distribuição do volume estimado pelo observado das RNAs 10 DAP-HC, 6 DAP-HC, 2 DAP-HC selecionadas para a FTFBP, FTFSM e TCF com 20% dados de validação .....	34

## LISTA DE TABELAS

<b>Tabela 1.</b> Variáveis utilizadas no treinamento das redes neurais artificiais (RNA) para as três fitofisionomias. ....	20
<b>Tabela 2.</b> Modelos matemáticos ajustados para estimativa de árvores em pé na floresta estadual do Amapá.....	21
<b>Tabela 3.</b> Coeficientes e estatísticas de qualidade de ajuste dos modelos de regressão para a fitofisionomia FTFBP, na Floresta Estadual do Amapá. ....	23
<b>Tabela 4.</b> Coeficientes e estatísticas de qualidade de ajuste dos modelos de regressão para a fitofisionomia FTFSM, na Floresta Estadual do Amapá. ....	24
<b>Tabela 5.</b> Coeficientes e estatísticas de qualidade de ajuste dos modelos de regressão para a fitofisionomia TCF, na Floresta Estadual do Amapá. ....	26
<b>Tabela 6.</b> Características das Redes neurais artificiais treinadas para fitofisionomia FTFDBP, na Floresta Estadual do Amapá.....	28
<b>Tabela 7.</b> Características das Redes neurais artificiais treinadas para fitofisionomia FTFSM, na Floresta Estadual do Amapá. ....	28
<b>Tabela 8.</b> Características das Redes neurais artificiais treinadas para fitofisionomia TCF, na Floresta Estadual do Amapá. ....	28
<b>Tabela 9.</b> Precisão das redes neurais artificiais selecionadas para a estimativa do volume m <sup>3</sup> FTFBP. ....	28
<b>Tabela 10.</b> Precisão das redes neurais artificiais selecionadas para a estimativa do volume m <sup>3</sup> FTFSM. ....	29
<b>Tabela 11.</b> Precisão das redes neurais artificiais selecionadas para a estimativa do volume m <sup>3</sup> TCF.....	30
<b>Tabela 12.</b> Resultado dos parâmetros estatísticos das RNAs e modelos matemáticos para estimativa do volume nas fitofisionomias FTFDBP, FTFSM e TCF.....	31

## SUMÁRIO

<b>RESUMO</b> .....	1
<b>ABSTRACT</b> .....	2
<b>1 INTRODUÇÃO</b> .....	3
<b>2 HIPÓTESE</b> .....	4
<b>3 OBJETIVOS</b> .....	4
3.1 Geral .....	4
3.2 Específicos.....	4
<b>4 REVISÃO BIBLIOGRÁFICA</b> .....	5
4.1 Modelos Volumétricos .....	5
4.2 Redes Neurais Artificiais.....	6
4.2.1 Histórico .....	6
4.2.2 O que é um neurônio artificial? .....	7
4.2.3 Função de Ativação .....	9
4.2.4 Arquitetura das redes neurais artificiais .....	10
4.2.5 Aprendizagem.....	12
<b>5 MATERIAL E MÉTODOS</b> .....	13
5.1 Área: .....	13
5.2 Clima: .....	14
5.3 Vegetação: .....	14
5.3.1 Floresta de Terra Firme de Baixo Platô.....	14
5.3.2 Floresta de Terra Firme de Densa Submontana.....	14
5.3.3 Transição Cerrado Floresta.....	15
5.4 Coleta de dados: .....	15
5.5 Análises de Dados: .....	19
5.5.1 Redes Neurais Artificiais.....	19
5.5.2 Ajuste dos modelos matemáticos: .....	21
<b>6 RESULTADOS E DISCUSSÃO</b> .....	22
6.1 Modelos Volumétricos .....	22
6.1.1 Floresta de Terra Firme de Baixo Platô:.....	22
6.1.2 Floresta de Terra Firme de Sub Montana: .....	24
6.1.3 Transição Cerrado Floresta:.....	26
6.2 Redes Neurais Artificiais:.....	27
6.2.1 Floresta de Terra Firme Densa de Baixo Platô:.....	28
6.2.2 Floresta de Terra Firme Densa de Sub Montana: .....	29
6.2.3 Transição Cerrado Floresta:.....	30
6.3 Avaliação dos melhores modelos matemáticos e RNAs .....	31



6. 4 Validação dos melhores modelos matemáticos e RNAs: .....	33
<b>7 CONCLUSÕES</b> .....	<b>37</b>
<b>8 REFERÊNCIAS BIBLIOGRÁFICAS:</b> .....	<b>38</b>

## RESUMO

As boas práticas de manejo florestal requerem estimativas do volume na floresta sejam obtidas com eficiência e precisão, para auxílio na tomada de decisões sobre o uso da floresta. A metodologia convencional aplicada consiste no uso do fator de forma para corrigir o volume cilíndrico e o ajuste de equações de regressão pelo método dos mínimos quadrados. Recentemente uma alternativa vem sendo usada, técnicas computacionais de inteligência artificial ou as chamadas redes neurais artificiais (RNA) que, também buscam estimativas precisas dos volumes das árvores inventariadas em pé. Diante disso esse estudo objetiva aplicar esta tecnologia para estimar o volume de árvores em pé na Floresta Estadual do Amapá. Foram cubadas 1028 árvores caídas em bom estado de conservação com  $DAP \geq 10\text{cm}$  pelo método de Smalian combinado com o de Hohenald em 30 unidades amostrais distribuídas em três fitofisionomias: Floresta de Terra Firme de Baixo Platô (FTFBP), Floresta de Terra Firme Submontana (FTFSM) e Transição Cerrado Floresta (TCF). Foram treinadas 50 redes neurais artificiais do tipo *Multilayer Perceptron* (MPL) para cada fitofisionomia usando DAP (diâmetro à altura do peito) e HC (altura do comercial) na camada de entrada e Volume ( $\text{m}^3$ ) na camada de saída. O tipo de treinamento aplicado foi o *Resilient Propagation* com função Sigmoidal e critérios de parada baseados em erro médio e número de ciclos. Os critérios usados para a avaliação da melhor RNA foram: análise gráfica dos resíduos, coeficiente de correlação ( $r_{\hat{y}y}$ ), *bias* (viés) e raiz quadrada do erro quadrático médio (RQME). Também foram ajustados cinco modelos volumétricos matemáticos via análise de regressão, tendo como variáveis independentes o DAP (diâmetro à altura do peito) e HC (altura do comercial). De acordo com os resultados obtidos, as RNAs e os modelos matemáticos apresentaram resultados semelhantes. As RNAs com arquitetura 2-6-1 com variáveis de entrada DAP e HC, algoritmo de treinamento (MLP), com 30.000 ciclos e função de ativação sigmoideal, produziram os melhores resultados nas redes treinadas. O modelo de regressão proposto de Schumacher e Hall foi o que melhor se ajustou aos dados, podendo ser utilizado para estimar o volume de árvores em pé na Floresta Estadual do Amapá em suas três fitofisionomias FTFBP, FTFSM E TCF.

**Palavra-chave:** relações quantitativas; inteligência artificial; floresta tropical.

## ABSTRACT

Good forest management practices require estimates of available forest volume to be efficiently and accurately obtained to assist in making forest use decisions. The conventional methodology applied consists of the use of the form factor to correct the cylindrical volume and the adjustment of regression equations by least squares method. Recently a new alternative has been used that uses computational techniques of artificial intelligence or the so-called artificial neural networks (ANNs) that also search for precise estimates of the volumes of the inventoried standing trees. Therefore, this study aims to apply this new technology to estimate the volume of standing trees in the Amapá State Forest. Volumes of 1028 fallen trees in good condition with  $DAP \geq 10\text{cm}$  were calculated by the Smalian method combined with the Hohenald method in 30 sample units distributed in three phytophysiognomies: Low Plateau Terra Firme Forest (FTFBP), Submontana Terra Firme Forest (FTFSM) and Forest-Savanna Transition (TCF). Fifty artificial neural networks of the Multilayer Perceptron type (MPL) were trained for each phytophysiognomy using DAP and HC (commercial height) in the inlet layer and Volume ( $\text{m}^3$ ) in the outlet layer. The type of training applied was Resilient Propagation with Sigmoidal function and stop criteria based on average error and number of cycles. The criteria used to evaluate the best RNA were: graphical analysis of residues, correlation coefficient ( $r_{\hat{y}y}$ ), bias and square root mean square error (RQME). Five mathematical volume models were also tested via regression analysis, with the independent variables being DAP (diameter at breast height) and HC (commercial height). According to the results obtained, ANNs and mathematical models presented similar results. ANNs with 2-6-1 architecture with DAP and HC input variables, training algorithm (MLP), with 30,000 cycles and sigmoidal activation function, produced the best results in the trained networks. The proposed regression model of Schumacher and Hall was the one that best fit the data, and can be used to estimate the volume of standing trees in the Amapá State Forest in its three phytophysiognomies FTFBP, FTFSM and TCF.

**Key words:** quantitative relations; artificial intelligence, tropical forest

## 1 INTRODUÇÃO

Dentre os objetivos do manejo florestal está o de obter produtos madeireiros aplicando princípios técnicos em sua operação, visando à sustentabilidade, e dessa forma, estabelecendo um viés econômico, ecologicamente correto e socialmente justo (SILVA, 2001).

As boas práticas do manejo florestal sustentável requerem a obtenção de informações para a tomada de decisões sobre a utilização da floresta. No caso da madeira, a quantificação do estoque volumétrico requer a aplicação de métodos eficientes de sua estimativa, que possibilite conhecer a sua capacidade produtiva ao mesmo tempo nortearas decisões silviculturais que busquem a máxima produção e rentabilidade da florestal (THAINES et al., 2010).

Dentre os métodos para estimar o estoque volumétrico, é mais comum o uso na ciência florestal de modelos matemáticos, ajusta os modelos estatísticos e se obtém equações (SANQUETTA et al., 2009).

Dentre os vários modelos para geração de equações de volume, o modelo de Schumacher & Hall (1993) é considerado o mais aplicável na área florestal, comparado aos vários modelos existentes para estimativas volumétricas. Isso pode ser associado ao fato de suas estimativas quase sempre resultarem em estimativas não tendenciosas (CAMPOS & LEITE, 2013).

Em busca de novas alternativas tem se usado técnicas computacionais de inteligência artificial, como as redes neurais artificiais (RNA) que têm mostrado resultados mais precisos que os modelos de regressão (BINOTI, 2014).

Redes neurais artificiais (RNAs) são sistemas massivos e paralelos, compostos por unidades de processamento simples que computam determinadas funções matemáticas (BRAGA et al., 1998). Assemelham-se em certa medida com os neurônios biológicos (SIMÕES; SHAW, 2007). A rede neural extrai seu poder computacional de sua estrutura paralela e distribuída, e, pela habilidade de aprender, consegue, dessa forma, generalizar o conhecimento adquirido. Essa capacidade da rede neural, a torna capaz de solucionar problemas como aproximação de função, classificação de padrões, agrupamento de dados e recuperação de conteúdo (HAYKIN, 2001).

Na ciência florestal as RNAs têm tido aplicações principalmente em mensuração florestal como, por exemplo, os trabalhos de Binoti et al (2009) que compararam os métodos de redes neurais artificiais e o modelo de Schumacher e Hall na estimativa do volume de árvores de eucalipto. Da mesma forma Ozçelik et al (2017) que utilizou redes

neurais artificiais para estimar a biomassa de pinheiros naturais na região oeste do mediterrâneo na Turquia.

Estudos relacionados à aplicação das redes neurais artificiais em florestas tropicais, são poucos e daí a necessidade da realização de mais estudos na aplicação dessa técnica nesse tipo de floresta.

Neste contexto, objetivo deste trabalho foi comparar redes neurais artificiais e modelos volumétricos estatísticos na estimativa do volume de árvores em pé na floresta estadual do Amapá em distintas fitofisionomias.

## **2 HIPÓTESE**

O uso das redes neurais artificiais como método de estimativa do volume de árvores em pé para diferentes fitofisionomias de uma floresta apresenta resultados mais precisos que as estimativas realizadas por modelos matemáticos obtidos via análise de regressão.

## **3 OBJETIVOS**

### **3.1 Geral**

Identificar as estimativas mais precisas do volume de árvores em pé em inventários florestais na floresta estadual do Amapá em suas diferentes fitofisionomias.

### **3.2 Específicos**

1. Estimar o volume de árvores em pé na floresta estadual do Amapá nas fitofisionomias Floresta de Terra Firme Densa de Baixo Platô (FTFDBP), Floresta de Terra Firme Densa de Submontana (FTFDSM) e Transição Cerrado-Floresta (TCF) utilizando RNAs.

2. Ajustar modelos matemáticos para estimar o volume de árvores em pé na floresta estadual do Amapá nas fitofisionomias Floresta de Terra Firme Densa de Baixo Platô (FTFDBP), Floresta de Terra Firme Densa de Submontana (FTFDSM) e Transição Cerrado-Floresta (TCF).

3. Apresentar dentre os métodos propostos, os de melhor desempenho quanto à precisão das estimativas.

## **4 REVISÃO BIBLIOGRÁFICA**

### **4.1 Modelos Volumétricos**

A estimativa dos volumes de árvores teve início com as construções manuais de tabelas contendo os volumes estimados de cada árvore de acordo com as variáveis usadas. Por isso, a literatura abordava o tema como “Tabelas de volumes” (LEITE; REGAZZI, 1992).

Desde a década de 80 e ainda nos tempos de hoje e comum se realizar o cálculo do volume com casca pela fórmula do volume cilíndrico, corrigido por um fator de forma (ff) de 0,7 (ROLIM et al., 2006). No entanto, quando calcula-se o volume a partir de modelos volumétricos ajustados para um local ou variável da floresta, obtém-se melhor exatidão. A modelagem do volume de árvores em função de variáveis independentes começou a ser desenvolvida na primeira metade do século XX. No entanto, o uso dessas técnicas realmente tomou maior impulso após o surgimento dos computadores, notadamente a partir da década de cinquenta (SCHNEIDER, 1993).

Nas equações utiliza-se de cubagem de árvores abatidas ou caídas naturalmente, esse método direto de estimação do volume de árvores e o mais utilizado na rotina de inventários florestais e consiste na medição sucessiva de diâmetros ao longo do tronco, dividindo-o em seções (HIGUCHI et al., 2008).

As equações geradas a partir dos modelos volumétricos apresentam-se como uma relação numérica expressa por equações capazes de exprimir o volume total ou parcial de uma árvore em função de variáveis independentes como diâmetro, altura, fator de forma, etc. (FINGER, 1992).

Finger (1992) e Scolforo (1997) classificaram os modelos matemáticos em lineares e não lineares. Os modelos lineares apresentam parâmetros que estão na forma aditiva e são divididos em equações de simples entrada ou dupla entrada. Simples entrada: o volume gerado por este tipo de modelo é função apenas de uma variável, sendo esta o diâmetro à altura do peito (DAP). Adota-se este procedimento quando há uma forte correlação entre essas variáveis de modo que se possa explicar a altura por meio do diâmetro.

Dupla entrada: o volume é gerado em função de duas variáveis,

mais usualmente o dap e a altura. Este modelo é utilizado na maioria das situações.

Tripla ou mais entradas: O volume resulta da utilização de mais de duas variáveis independentes além do dap e da altura, como por exemplo, o fator de forma, a altura da copa e a espessura da casca.

As equações não lineares são aquelas onde pelo menos um dos parâmetros não está na forma aditiva, podendo apresentar, formas exponenciais ( $Y = \beta_0 e^{\beta_1 X}$ ), geométricas ( $Y = \beta_0 X^{\beta_1}$ ) ou pela multiplicação dos fatores. Exemplo: Dap x Altura é um modelo não linear se for ajustado dessa forma.

Os modelos que mais se destacam são o de Schumacher e Hall e Spurr. Campos et al. (2013) descrevem que o modelo de volume de Schumacher e Hall na forma logarítmica tem sido o mais difundido, talvez por suas propriedades estatísticas, uma vez que resulta quase sempre em estimativas não-tendenciosas. O mesmo autor comenta que a grande difusão do modelo de Spurr deve ser atribuída à facilidade de ajustamento, pois, volumes de árvores menores são estimados com precisão.

Hoje os modelos volumétricos são essenciais na atividade florestal, uma vez que quantificar o volume de madeira é imprescindível para o planejamento estratégico de planos de manejo sustentáveis (LEITE & ANDRADE, 2002). Além disso, a legislação que regulamenta os planos de manejo florestal sustentável no Brasil, exige a utilização de equações volumétricas.

## **4.2 Redes Neurais Artificiais**

### **4.2.1 Histórico**

Segundo Cardon et al (1994), os primeiros trabalhos sobre Redes Neurais Artificiais foram realizados no ano de 1943, por McCulloch e Pitts. Estes cientistas desenvolveram um estudo sobre o comportamento do neurônio biológico, com o objetivo de criar um modelo matemático, e chegaram a conclusões de extrema importância para a futura implementação computacional do neurônio.

Segundo Braga et al (1998), Hebb mostrava que a aprendizagem de redes neurais era adquirida por meio da variação de pesos de entradas dos neurônios. Em 1958 Rosenblatt em seu livro Perceptrons traz uma ideia muito importante que impulsionou a maior parte das pesquisas na área. Este cientista apresentou uma nova abordagem para o problema de reconhecimento de padrões (HAYKIN, 2001).

No ano de 1969, a publicação do trabalho realizada pelos pesquisadores Minsky e Papert, também

intitulado como perceptrons, trouxe a área da pesquisa com redes neurais artificiais uma estagnação ao demonstrar através de seus estudos que havia matematicamente limites para se aplicar perceptrons de camada única, como por exemplo, a incapacidade de solucionar problemas simples como o de função lógica para duas ou mais variáveis (BRAGA et al, 1998).

Na década de 80 os estudos com redes neurais artificiais tiveram uma grande retomada com o trabalho de Rumelhart, que desenvolveu o algoritmo back propagation, que proporcionou o treinamento de redes perceptrons de múltiplas camadas com maior generalização, possibilitando diversas aplicações (HAYKIN, 2001).

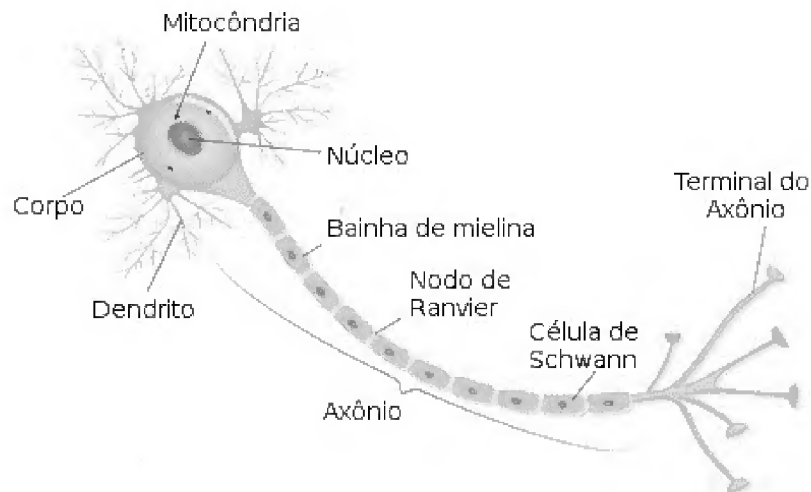
#### **4.2.2 O que é um neurônio artificial?**

Redes neurais artificiais ou RNA são ferramentas computacionais utilizadas para solucionar vários problemas como: tarefas de aprendizagem, aproximação de funções, classificação de padrões, agrupamento de dados, predição, otimização e recuperação de dados entre outras aplicações. A RNA foi desenvolvida com inspiração no cérebro humano e tem por objetivo obter a rapidez e a precisão de processamento de informações (CARDON, 1994).

O sistema nervoso humano é formado por um conjunto extremamente complexo de células, os neurônios. Eles têm um papel essencial na determinação do funcionamento e comportamento do corpo humano e do raciocínio. Os neurônios são formados pelos dendritos, que são um conjunto de terminais de entrada, pelo corpo central, e pelos axônios que são longos terminais de saída. Um esquema dos constituintes da célula neural pode ser visto na Figura 1.

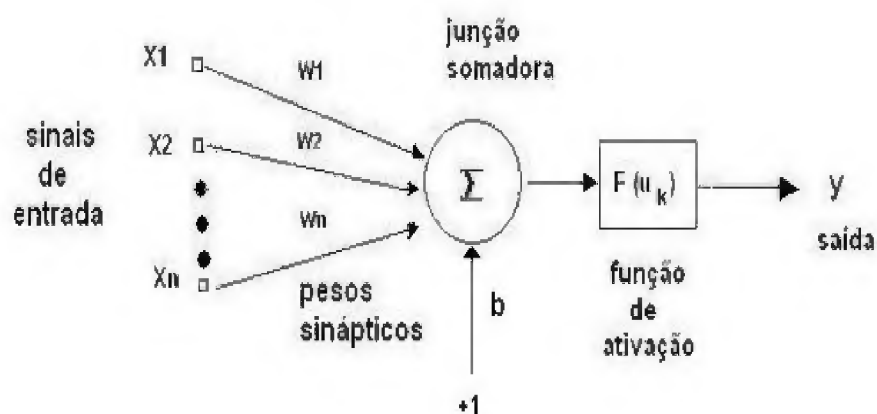


**Figura 1.** Anatomia de um neurônio (Fonte: Moreira, 2017)



Assim como o sistema nervoso é composto por vários neurônios biológicos, a rede neural artificial é também formada por unidades que nada mais são que pequenos módulos que simulam o funcionamento de um neurônio. Estes módulos devem funcionar de acordo com os elementos em que foram inspirados, recebendo e retransmitindo informações (HAYKIN, 2001) na figura 2 temos um exemplo do modelo de neurônio artificial.

**Figura 2.** Modelo de um neurônio artificial (Fonte: Haykin, 2001).



O funcionamento básico do neurônio artificial consiste no somatório de cada entrada ( $x_1, x_2, \dots, x_n$ ) multiplicado pelo peso associado ( $w_1, w_2, \dots, w_n$ ), além de uma entrada sempre com valor +1, produzindo um nível de atividade. O resultado passa por uma função de ativação  $F(u_k)$ , que é disparada produzindo uma resposta de saída ( $y$ ), que é submetida aos nós da camada seguinte.

### 4.2.3 Função de Ativação

A função de ativação tem como objetivo restringir a amplitude da saída do neurônio, isto é, limitar a sua saída a um intervalo de valor finito. Ainda a função de ativação determina se o neurônio pode ser determinístico ou estocástico dependendo do tipo da função de ativação proposta para o neurônio (BINOTI, 2012); (HAYKIN, 2001).

São três os tipos de funções de ativação mais usados para uma rede neural artificial, cujos gráficos são mostrados na figura 3:

**Função de limiar:** A saída do neurônio assume valor 0 quando seu resultado for negativo e 1 quando for positivo (Figura 3a).

$$f(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ 0 & \text{se } u < 0 \end{cases} \quad \text{Eq.1}$$

**Função linear:** Esse tipo de função pode ser visto como uma aproximação de um amplificador não-linear (Figura 3b).

$$f(u) = \begin{cases} 1 & \text{se } u \geq +\frac{1}{2} \\ u & \text{se } u + \frac{1}{2} > u > -\frac{1}{2} \\ 0 & \text{se } u \leq -\frac{1}{2} \end{cases} \quad \text{Eq.2}$$

**Função sigmoide:** É o tipo de função mais largamente utilizada na construção das redes neurais artificiais. É uma função estreitamente crescente. Pode ser de várias formas, sendo as mais comuns a função logística (Figura 3c).

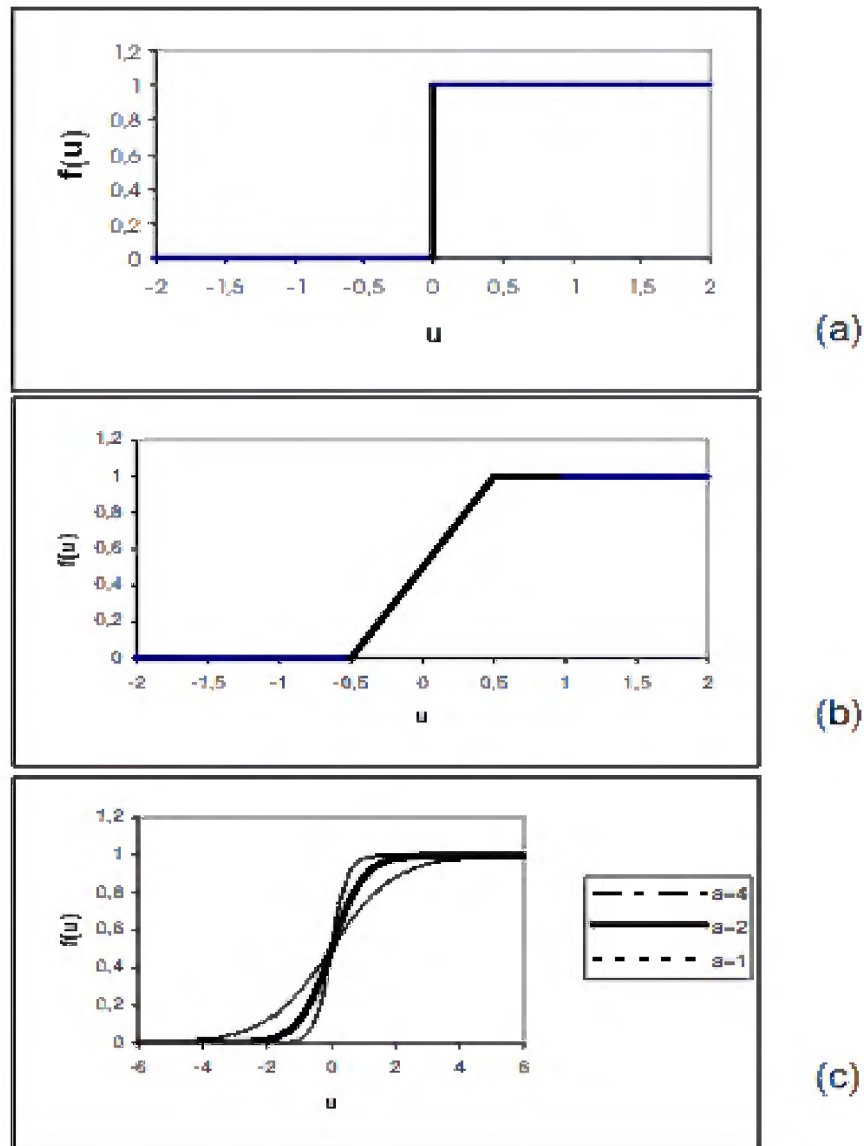
$$f(u) = \frac{1}{1+e^{-au}} \quad \text{Eq.3}$$

Onde (a) é o parâmetro de inclinação da função (quanto maior o valor de a, mais inclinada se torna a curva), e a função tangente hiperbólica.

$$f(u) = \tanh(u) \quad \text{Eq.4}$$

É importante salientar que as funções descritas anteriormente (excetuando-se a função tangente hiperbólica (equação 4), estão definidas no intervalo de 0 a +1, porém, é comum verificarmos implementações onde a função se estende de -1 a +1.

**Figura 3.** (a) Função de limiar, (b) Função linear, (c) Função sigmoide com parâmetro de inclinação a variável.



#### 4.2.4 Arquitetura das redes neurais artificiais

A forma pela qual os elementos de processamento (neurônios) e suas conexões (sinapses) são organizados em uma rede neural artificial possui relação direta ao tipo de problema a ser aplicado (CARDON, 1994).

Uma rede neural é composta por camadas. Em sua forma mais simples, há uma camada de entrada de nós que projeta-se sobre uma camada de saída de neurônios (Figura 4). Esta rede é chamada de rede de camada única, sendo que tal designação se refere somente à camada dos nós computacionais (neurônios). A camada de entrada não é mencionada, pois nela não é realizada qualquer cálculo (HAYKIN, 1999).

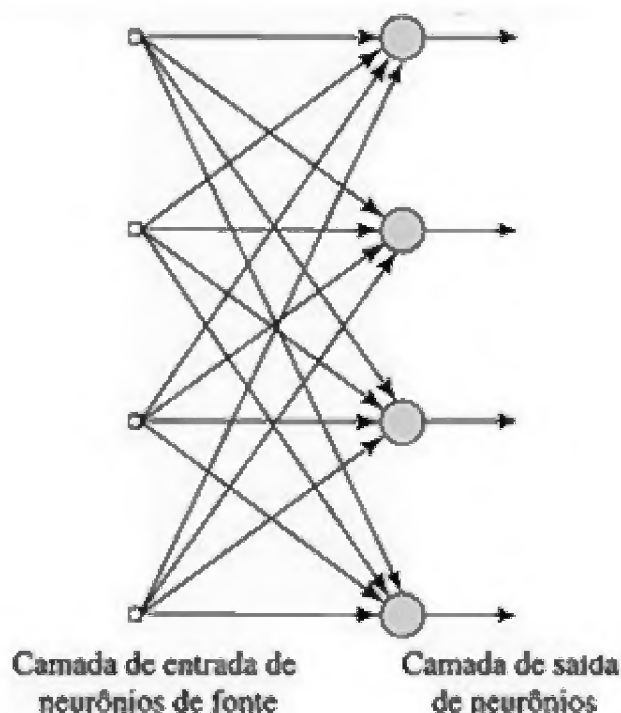
A rede com múltiplas camadas diferencia-se pela presença de uma ou mais

camadas ocultas, cujos nós computacionais são chamados de neurônios ocultos. Adicionando-se uma ou mais camadas ocultas, a rede adquire uma perspectiva global apesar de sua conectividade local, devido ao conjunto extra de conexões sinápticas e da dimensão extra de interações neurais (CHURCHLAND; SEJNOWSKI, 1994).


Os nós da camada de entrada da rede alimenta a primeira camada de neurônios (primeira camada oculta) cujos sinais processados são enviados aos neurônios da segunda camada. Os sinais de saída da segunda camada são utilizados como entradas para a terceira camada, e assim por diante por todo resto da rede (HAYKIN, 2001).

O conjunto de sinais de saída dos neurônios da camada de saída (final) da rede constitui a resposta global para o padrão fornecido pelos nós de fonte da camada de entrada. Na figura 5 é ilustrada uma rede neural de múltiplas camadas alimentada para frente com única camada oculta referida como uma rede 10-4-2, pois sua estrutura é constituída por 10 nós na camada de entrada, 4 neurônios ocultos e 2 neurônios de saída.

**Figura 4.** Rede neural com uma única camada (Fonte: Haykin, 1999)



**Figura 5.** Rede Neural Feed forward com múltiplas camadas (Fonte: Haykin, 1999).



#### 4.2.5 Aprendizagem

O princípio básico das RNA é o de que elas podem adquirir “conhecimento” com a experiência, ou seja, podem “aprender” por meio de exemplos ou problemas conhecidos que sejam apresentados a elas. Este processo inicia-se quando se precisa obter a solução para um determinado grupo de problemas, cuja solução é conhecida para uma série de problemas semelhantes (BRAGA et al, 1998).

Monta-se então uma RNA com uma camada de entrada, composta por: N unidades, que receberão os N dados de entrada do problema; camadas ocultas cujo número varia em função do problema; e uma camada de saída, composta por M unidades, que deverão fornecer os M dados de saída que caracterizam a solução do problema (LASTIRI; PAULETTI, 2004).

Considerando-se os problemas cujas soluções são conhecidas, deve-se obter o conjunto dos pesos das conexões entre todas as unidades da RNA, estes pesos inicialmente recebem valores aleatórios, que posteriormente vão sendo reajustados de acordo com o treinamento da rede (FERNEDA, 2006).

O processo básico de treinamento é receber as entradas, realizar os cálculos necessários da rede e comparar o resultado obtido com o

resultado esperado, se o resultado obtido for diferente do esperado então os pesos da rede são reajustados. Para reajustar os pesos, é calculado o erro da rede, que seria a diferença da saída obtida e a saída esperada. A função de ajuste de pesos geralmente usada é apresentada na equação:

$$w(i) = w(i) + a \times \varepsilon \times x(i) \quad \text{Eq.5}$$

Onde  $a$  é definido pelo desenvolvedor,  $\varepsilon$  é o erro, geralmente proposto por:

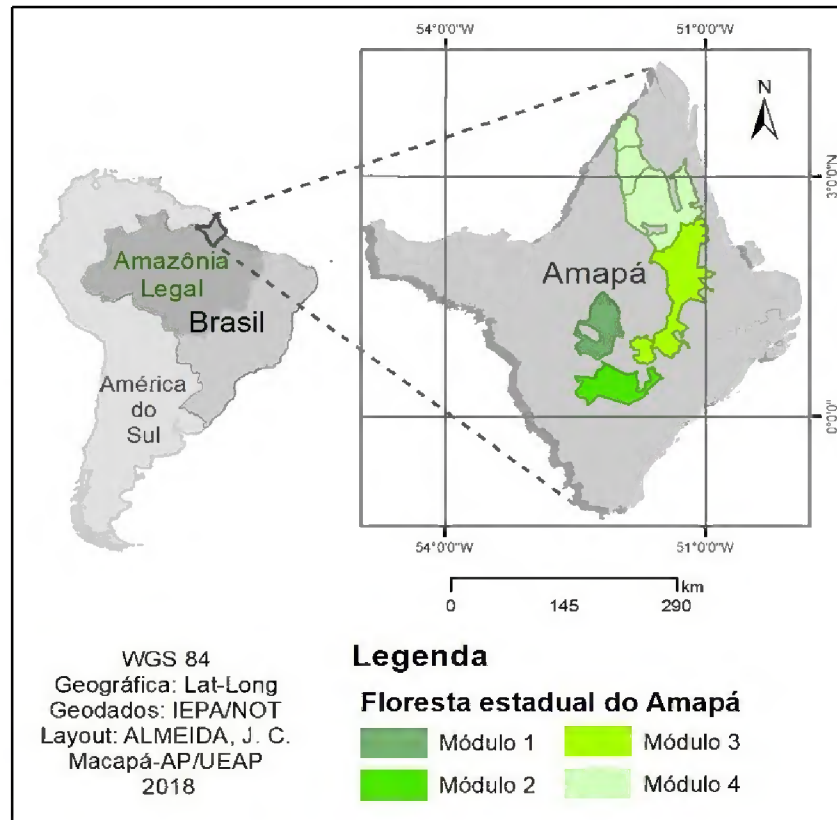
$$y(\text{esperado}) - y(\text{obtido}).$$

## 5 MATERIAL E MÉTODOS

### 5.1 Área

A Floresta Estadual do Amapá (FLOTA/AP) localiza-se na região central do estado do Amapá, Brasil. A unidade de conservação de uso sustentável compreende uma área descontínua de 2.369.400 hectares dividida em quatro módulos produtivos (Figura 6).

**Figura 6.** Localização da Floresta Estadual do Amapá (Fonte: Almeida, 2018)



## 5.2 Clima:

O clima da região é do tipo Am (equatorial super-úmido), segundo a classificação de Köppen. A temperatura média é 25°C, ocorrendo pouca variação de temperatura durante o ano. A precipitação anual na região varia de 2.700 a 2.900 mm. O índice pluviométrico mensal mais seco abaixo de 200 mm (SOUZA; CUNHA, 2010).

## 5.3 Vegetação:

A vegetação predominantemente é floresta ombrófila densa de baixos platôs (FTFDBP) e submontana (FTFDMS), bem como transição cerrado-floresta (TCF), considerando toda a área da FLOTA/AP também podem ser encontrados ambientes de mangue, campos e várzea em pequenas áreas (IBGE, 2012).

### 5.3.1 Floresta de Terra Firme de Baixo Platô

Apresenta dossel de alto porte, até 50 m, perenifólia, em planícies costeiras. Estima-se em 245 o número de espécies arbóreas que compõem esta fitofisionomia, com destaque para *Eschweilera coriacea* (DC.) S. A. Mori, *Pouteria caimito* (Ruiz & Pav.) Radlk., *Protium tenuifolium* (Engl.) e *Minquartia guianensis* (Aubl). Os afloramentos rochosos são encontrados com baixa intensidade. A declividade varia de ondulada a fortemente ondulada. Possui formação geológica pré-cambriana, com superfícies pedi planado por canais geralmente curtos, numerosos e pouco aprofundado. O solo predominante é tipo Latossolo Vermelho-Amarelo distrófico. A altitude varia de 60 a 100 m (IEF, 2016).

### 5.3.2 Floresta de Terra Firme de Densa Submontana

Situada em encostas, com dossel uniforme e de alto porte (até 50 m), perenifólia. O número de espécies arbóreas é de 176, com destaque para *Eschweilera coriacea* (DC.) S. A. Mori, *Pouteria caimito* (Ruiz & Pav.) Radlk., *Inga auristella* Harms, *Guarea Pubescens* Subsp. pubiflora (A. Juss.) T.D. Penn e *Vouacapoua americana* Aubl. Os afloramentos rochosos são encontrados em intensidade de baixa a moderada. A declividade varia de ondulada a fortemente ondulada. Possui formação geológica pré-cambriana, com relevo montanhoso e medianamente profundo. O solo predominante é tipo Latossolo Vermelho-Amarelo distrófico. A altitude máxima registrada é 320 m, com média de 195 m (IEF, 2016).

### 5.3.3 Transição Cerrado Floresta

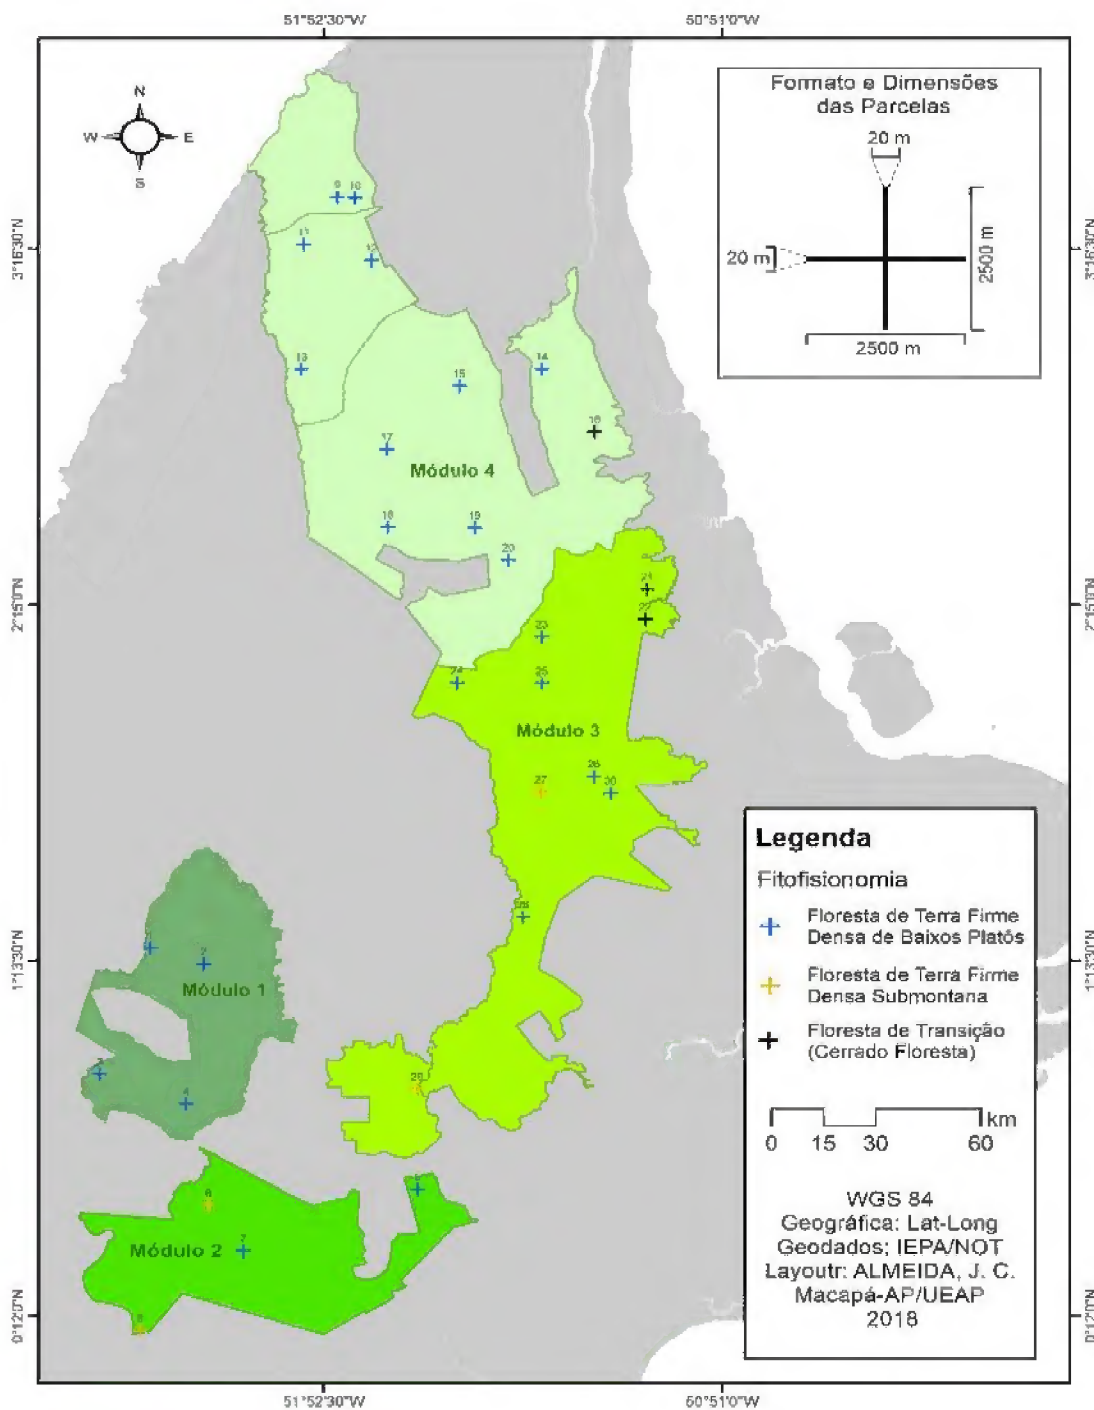
Situada em área mais próxima do litoral, com dossel uniforme e de médio porte (até 30 m), perenifólia. Foram registradas espécies arbóreas nesta fitofisionomia, com maior representatividade para *Pouteria caimito* (Ruiz & Pav) Radlk, *Protium decandrum* (Aubl) March e *Guarea Pubescens Subsp. pubiflora* (A. Juss.) T.D. Penn, bem como espécies típicas do cerrado: *Ormosia coccínea* Jacks., *Perebea* sp., *Cheiloclinium cognatum* (Miers) A.C. Sm. Os afloramentos rochosos são encontrados de moderada a alta intensidade. A topografia é plana e possui formação geológica pré-cambriana, com drenagem pouco profunda. O solo predominante é tipo Latossolo Amarelo distrófico e concrecionários lateríticos. A altitude média encontrada é de 60 m (IEF, 2016).

### 5.4 Coleta de dados:

Os dados usados para realização desse estudo foram fornecidos pelo - IEF-AP Instituto Estadual de Florestas do Amapá que realizou medição de árvores amostra em parceria com o INAM - Instituto Natureza Amazônica, durante o inventário amostral conduzido por aquela instituição na Floresta Estadual Amapá. Foram alocadas aleatoriamente 30 unidades amostrais em três distintas fitofisionomias, estabelecidas seguindo o sentido Norte-Sul / Leste-Oeste, a partir de faixas contínuas de 20 x 2500 m em forma de cruz (Figura 7) (IEF, 2016).




**Figura 7.** Localização das (trinta) 30 unidades amostrais onde foram realizadas as coletas na Floresta Estadual do Amapá (Fonte: Almeida, 2018)



O inventário incluiu as árvores naturalmente caídas em bom estado de conservação com DAP (Diâmetro a altura do peito medido a 1,30 m do solo) maiores ou iguais a 10 cm, presentes nas 30 unidades amostrais. O volume individual das árvores cubadas foi obtido por meio da combinação de dois métodos: o de Smalian (medição dos diâmetros na base e do topo de cada seção) e de Hohenald (divisão relativa do comprimento da seção). Pela facilidade de a árvore estar no chão, mediram-se as alturas

comerciais (comprimento do fuste até a primeira bifurcação) e altura total com o auxílio de trena métrica. A altura comercial foi dividida em 10 partes (ou seções), sendo que em cada seção foram medidos os diâmetros da base e do topo com o auxílio de uma suta (Figura 8).

**Figura 8.** Esquema de cubagem de árvores caídas dividindo a altura comercial em 10 partes (Fonte: Gomes, 2008)

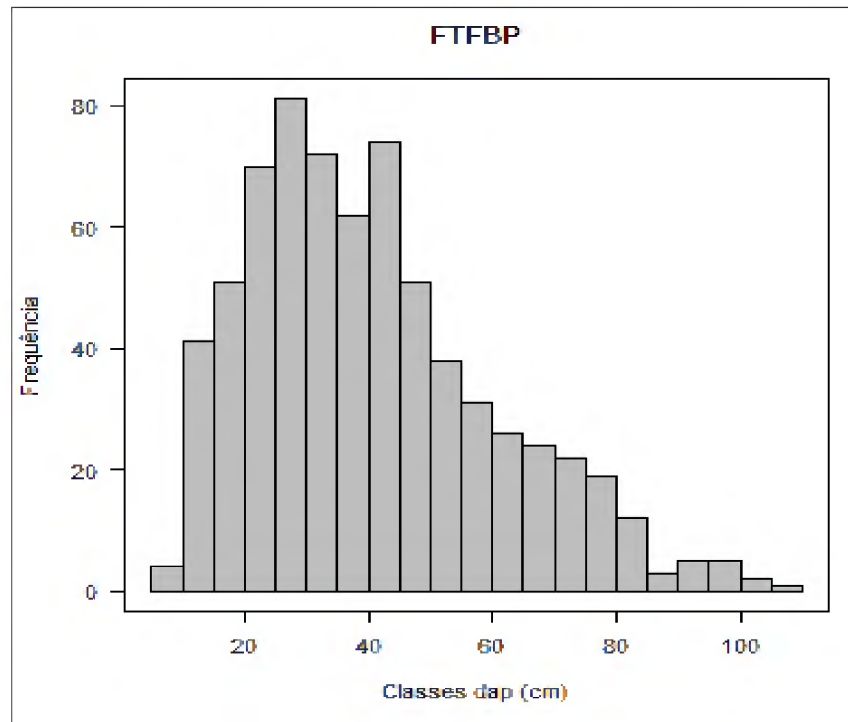


O volume de cada seção resulta da multiplicação da área basal média (base e topo) pelo comprimento da seção (1/10 da altura comercial). O somatório dos volumes das 10 seções constitui o volume total da árvore, dado pela fórmula:

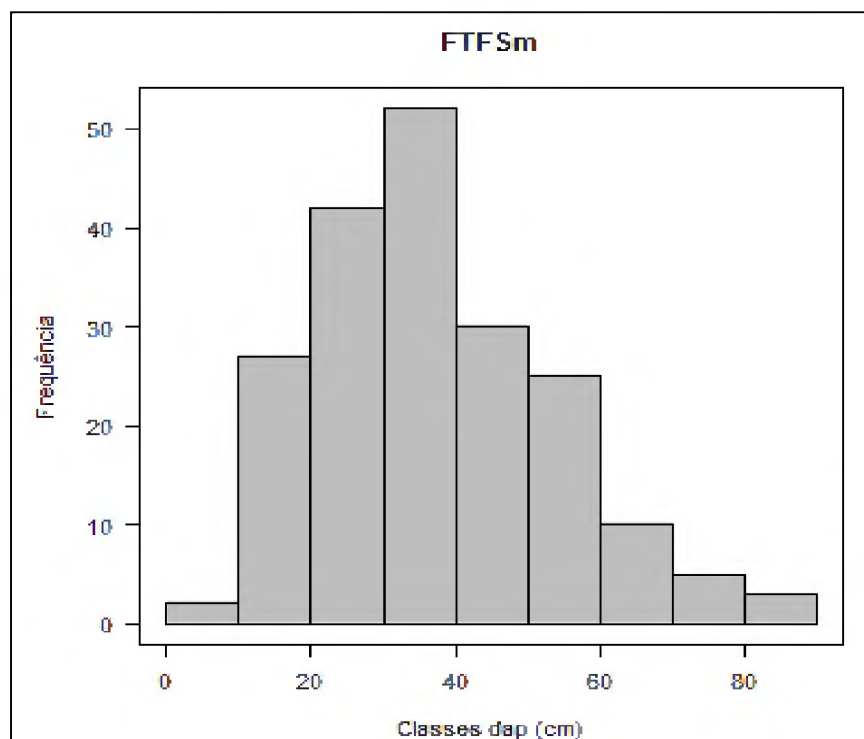
$$V = \frac{\pi}{4} \times \left( \frac{D_0^2 + D_{10}^2}{2} + D_1^2 + D_2^2 + D_3^2 + D_4^2 + D_5^2 + D_6^2 + D_7^2 + D_8^2 + D_9^2 \right) \times \frac{H}{10} \text{ Eq.6}$$

Foram cubadas 1028 árvores amostra encontradas tombadas nas 30 unidades amostrais distribuídas nos três estratos florestais. Da seguinte maneira: 694 na fitofisionomia de Floresta de Terra Firme Densa de Baixo Platô (FTFDBP), 196 na fitofisionomia Floresta de Terra Firme Densa de Submontana (FTFDSM) 138 na fitofisionomia Transição Cerrado-Floresta (TCF) (IEF,2016). Nas figuras 9-11 são apresentadas as distribuições dos diâmetros em classes diamétricas, mostrando a frequência de cada classe de DAPs.

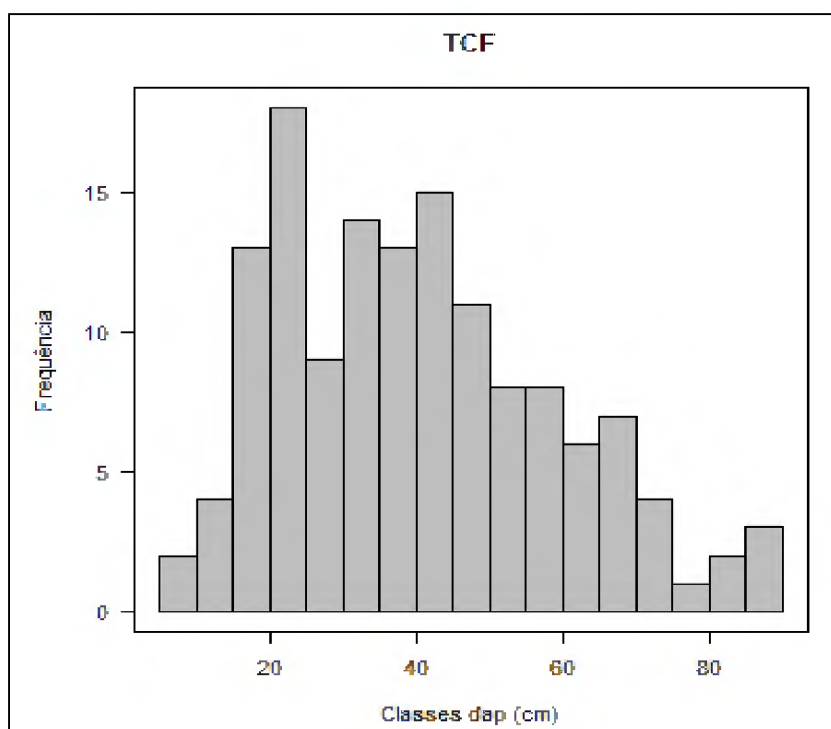
**Figura 9.** Distribuição de frequência das árvores amostradas por diâmetro (DAP) na fitofisionomia Floresta de Terra Firme de Baixo Platô



**Figura 10.** Distribuição de frequência das árvores amostradas por diâmetro (DAP) na fitofisionomia Floresta de Terra Firme Densa de Submontana



**Figura 11.** Distribuição de frequência das árvores amostradas por diâmetro (DAP) na fitofisionomia Transição Cerrado Floresta



## 5.5 Análises de Dados:

### 5.5.1 Redes Neurais Artificiais

Para o treinamento e avaliação das redes foi utilizado o sistema Neuro Forest 3.0, disponível gratuitamente no site <http://neuroforest.ucoz.com>. Foram utilizadas RNAs com a arquitetura de múltiplas camadas, comumente conhecidas com *Multilayer Perceptron* (MLP) (HAYKIN, 2001).

Para a escolha das funções de ativação (sigmoideal) da camada oculta e de saída. Considerou-se o treinamento Supervisionado, empregando o algoritmo da retropropagação do erro (*Back propagation*), como regra de aprendizagem por correção de erro. Aplicou-se o algoritmo de mínimo quadrado médio, para a regra de aprendizado, o qual tem por objetivo encontrar um conjunto de pesos e polarizações que reduzam a função erro (HAYKIN, 2001). Os critérios de parada foram estabelecidos com base no erro médio e número de ciclos (erro de 1% e 30.000 ciclos).

Foram treinadas cinquenta redes neurais artificiais (RNA) para cada fitofisionomia com a variável de entrada combinadas ou não as variáveis dendrométricas: Dap; Dap<sup>2</sup>; 1/Dap; Hc; Log Dap; Log Dap<sup>2</sup>; Log Hc e para variável de saída Volume m<sup>3</sup> (Tabela1).

Do número total de árvores amostradas foram selecionadas, aleatoriamente, 80% para o ajuste: FTFBP-555, FTFSM-157, TCF-110 e 20% para validação: FTFBP-139, FTFSM-39, TCF-28.

**Tabela 1.** Variáveis utilizadas no treinamento das redes neurais artificiais (RNA) para as três fitofisionomias.

RNA	Variáveis de Entrada	Estrutura	Saída
1-10	<i>DAP</i>	1-6-1	<i>Volume</i>
1-10	<i>DAP; Hc</i>	2-6-1	<i>Volume</i>
1-10	<i>LogDAP; LogHc;</i>	2-6-1	<i>Volume</i>
1-10	<i>LogDAP ; LogHc</i>	2-6-1	<i>Volume</i>
1-10	<i>DAP; 1/DAP; DAP</i>	3-6-1	<i>Volume</i>

DAP: Diâmetro a altura do peito (cm); Hc: Altura comercial (m).

Os critérios estatísticos para a avaliação da melhor rede foram: coeficiente de correlação ( $R_{\hat{y}y}$ ), bias, raiz quadrada do erro quadrático médio (RQME), análise gráfica dos resíduos (BINOTI, 2009), calculadas pelas seguintes expressões:

$$R_{\hat{y}y} = \frac{n^{-1} \sum_{i=1}^n (\hat{Y}_i - \bar{Y}_m)(Y_i - \bar{Y})}{\sqrt{n^{-1} \sum_{i=1}^n (\hat{Y}_i - \bar{Y}_m)^2 (n^{-1} \sum_{i=1}^n (Y_i - \bar{Y}_m)^2)}} \quad \text{Eq.6}$$

Onde:

$Y_i$  = Valores observados;

$\hat{Y}_i$  = Valores estimados;

$\bar{Y}$  = Média dos valores da variável sob análise;

$n$  = número de observações.

$$\text{Bias} = n^{-1} \sum_{i=1}^n (Y_i - \hat{Y}) \quad \text{Eq.7}$$

Onde:

$Y_i$  = Valores Observados;

$\bar{Y}$  = Média dos valores da variável sob análise;

$n$  = Número de observações.

$$RQME = 100\bar{Y}^{-1}\sqrt{n^{-1}\sum_{i=1}^n(Y_i - \hat{Y}_i)^2} \quad \text{Eq.8}$$

Onde:

$Y_i$  = Valores Observados;

$\hat{Y}_i$  = Valores Estimados;

$\bar{Y}$  = Média dos valores da variável sobre análise;

$n$  = Número de observações.

### 5. 5.2Ajuste dos modelos matemáticos:

Foi ajustado cinco modelos, de uso frequente na mensuração florestal via análise de regressão (Tabela 2), para as três distintas fitofisionomias. As variáveis consideradas foram diâmetro altura do peito 1,30 (DAP), Altura Comercial (HC) e o Volume (m<sup>3</sup>). A análise foi feita por meio do programa R Studio (R Core Team, 2017).

**Tabela 2.** Modelos matemáticos ajustados para estimativa de árvores em pé na floresta estadual do Amapá.

N	Modelo	Autor
1	$V = \beta_0 + \beta_1 DAP^2 + \varepsilon$	Koperzky e Gehrhardt
2	$Ln(V) = \beta_0 + \ln(DAP) \beta_1 + \varepsilon$	Husch
3	$Ln(V) = \beta_0 + \beta_1 \ln DAP + \beta_2 DAP^{-1} + \varepsilon$	Brenac
4	$V = \beta_0 + \beta_1 DAP^2 + \beta_2 DAP^2 H + \beta_3 H + \varepsilon$	Stoate
5	$Ln(V) = \beta_0 + \beta_1 \ln DAP + \beta_2 \ln H + \varepsilon$	Schumacher e Hall

Onde: V=Volume (m<sup>3</sup>); DAP=diâmetro a 1,30m do solo(cm); H = altura da árvore (m);  $\beta_0$ ,  $\beta_1$ ,  $\beta_2$  e  $\beta_3$  = coeficientes;  $\varepsilon$ =erro; ln=logaritmo natural.

Para análise da estimativa foram calculadas as seguintes estatísticas de qualidade: coeficiente de determinação ajustado em porcentagem ( $R_{aj}^2\%$ ), Erro padrão da estimativa ( $S_{yx}$ ), Erro padrão da estimativa em percentual ( $S_{y,x}\%$ ), Raiz do Erro Quadrático Médio (RQME), Coeficiente de correlação ( $R_{\hat{y}y}$ ), Bias, além da análise gráfica dos resíduos, para verificar a presença de tendenciosidade nas estimativa do volume (BINOTI, 2009) calculados pelas seguintes expressões:

$$R_{Aj}^2\% = 1 - \left[ (1 - R^2) \frac{n-1}{n-p-1} \right] \quad \text{Eq.8}$$

Onde:

$R_{aj}^2$  = Coeficiente de Determinação Ajustado;

$n$ =número de dados observados;

$P$ =número de coeficientes do modelo.

$$S_{y.x} = \sqrt{QM_{res}} \quad \text{Eq.9}$$

Onde:

$S_{y.x}$  = erro padrão da estimativa;

$QM_{res}$  = quadrado médio do resíduo, obtido na análise de variância.

$$S_{y.x}\% = \left( \frac{S_{y.x}}{\bar{Y}_{real}} \right) \cdot 100 \quad \text{Eq. 10}$$

Onde:

$S_{y.x}\%$  erro padrão da estimativa percentual;

$\bar{Y}_{real}$  a média aritmética do volume real.

$$RQME = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2} \quad \text{Eq.11}$$

Onde:

$P_i$  são os valores estimados;

$O_i$  são os valores observados e  $n$  é o número de observações.

## 6 RESULTADOS E DISCUSSÃO

### 6.1 Modelos Volumétricos

#### 6.1.1 Floresta de Terra Firme de Baixo Platô:

Para o ajuste da fitofisionomia FTFBP foram utilizadas 555 árvores e para a validação 139 árvores, totalizando 694 árvores para essa fitofisionomia. O volume observado foi de 1098,077 m<sup>3</sup> com um valor médio 1,5822 m<sup>3</sup> por árvore.

**Tabela 3.** Coeficientes e estatísticas de qualidade de ajuste dos modelos de regressão para a fitofisionomia FTFBP, na Floresta Estadual do Amapá.

Mod	b0	b1	b2	b3	R <sup>2</sup> aj%	Syx%	Bias	RQME	R <sup>2</sup> yy
1	-8,2610	2,2601			90,02	38,20	0,16704	0,78399	0,94879
2	-4,4583	0,3285			89,24	39,67	0,17777	0,93320	0,94467
3	-7,7576	2,2099	-1,1129		90,00	38,24	0,17162	0,78250	0,94871
4	-9,1901	0,0082	0,9583	0,0824	97,78	17,96	0,03960	0,40654	0,98891
5	-9,2875	1,9570	0,8898		97,80	17,94	0,03937	0,40405	0,98893

Onde: b0, b1, b2, b3 = coeficientes  $R_{aj}^2\%$  = Coeficiente de determinação ajustado;  $S_{y,x}\%$  = erro padrão da estimativa; Raiz do erro quadrático médio (RQME),  $R^2_{yy}$  = Coeficiente de correlação, Bias.

Na Tabela 3 os modelos 4 e 5 apresentam um valor superior aos outros modelos para o coeficiente de correlação igual a 0,98891 e 0,98893 respectivamente. Os modelos 4 e 5 apresentaram os menores valores para Syx %, RQME, enquanto que os modelos 1, 2 e 3 os maiores valores.

Os modelos 1, 2 e 3 (Koperzky e Gehrhardt, Husch, Brenac) foram os que apresentaram os piores resultados para a estimativa do volume m<sup>3</sup>.

Os modelos 4 e 5 (Stoate e Schumacher e Hall) obtiveram resultados semelhantes nas métricas do ajuste com uma pequena melhora para ao modelo 5 por apresentar melhores resultados para Raj<sup>2</sup>%, Syx%, (97,80; 17,94).

Na figura 12 são apresentadas as distribuições de resíduos dos cinco modelos ajustados (Koperzky e Gehrhardt, Husch, Brenac, Stoate e Schumacher e Hall).

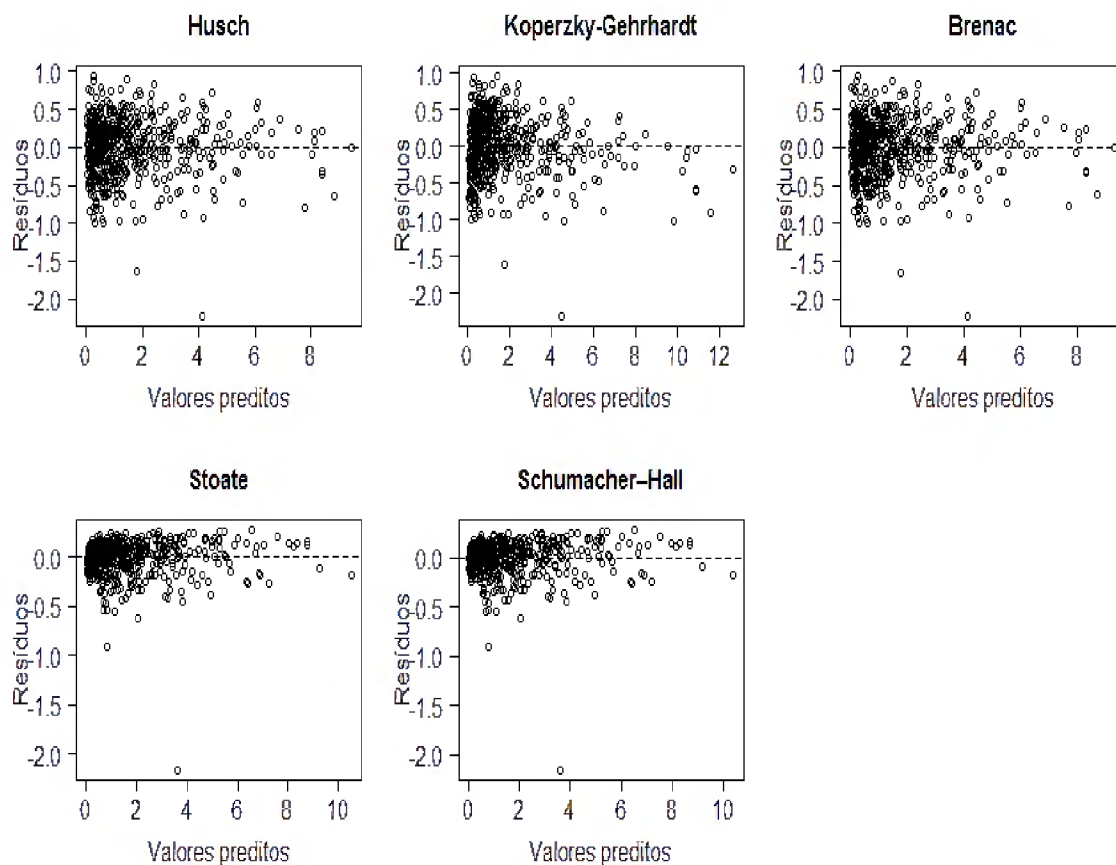
Os gráficos de dispersão de resíduo são utilizados para verificar a presença do erro e o comportamento das discrepâncias dos dados. Através da análise gráfica verificou-se de houve tendenciosidade de subestimativa e superestimativa nos modelos 1, 2 e 3. Os gráficos dos modelos 4 e 5 apresentaram melhor distribuição na comparação com os modelos 1, 2 e 3.

Segundo

Campos e Leite (2013) possível presença de outliers (dados discrepantes), desacreditando os limites de confiança das estimativas, tendo como solução a troca de modelo ou transformação da variável dependente para logaritmo ou a justaposição de modelos, ou ainda ponderação de variáveis.



**Figura 12.** Distribuição dos resíduos em função dos valores preditos, para os cinco modelos ajustados para a fitofisionomia FTFDBP



### 6.1.2 Floresta de Terra Firme de Sub Montana:

Para o ajuste da fitofisionomia FTFSM foram utilizadas 157 árvores e para a validação 39 árvores, onde totalizou 196 árvores para essa fitofisionomia. O volume observado foi de 245,145 m<sup>3</sup> com um valor médio 1,250 m<sup>3</sup> por árvore.

**Tabela 4.** Coeficientes e estatísticas de qualidade de ajuste dos modelos de regressão para a fitofisionomia FTFSM, na Floresta Estadual do Amapá.

Mod	b0	b1	b2	b3	R <sup>2</sup> aj%	S <sub>y,x</sub> %	Bias	RQME	R <sub>yy</sub>
1	-9,1201	2,4777			93,52	32,51	0.11016	0.5987	0.9670
2	-4,9816	0.3627			93,10	33,56	0.12023	0.6884	0.9648
3	-8,3712	2,0265	0.0664		93,50	32,56	0.10483	0.5961	0.9669
4	-8,6792	0.0638	0.8037	0.0139	99,01	12,66	0.02153	0.2693	0.9950
5	-9,3986	2,0407	0.8178		99,03	12,56	0.01712	0.2573	0.9951

Onde: b0, b1, b2, b3 = coeficientes R<sup>2</sup><sub>aj</sub>% = Coeficiente de determinação ajustado; S<sub>y,x</sub>% = erro padrão da estimativa; Raiz do erro quadrático médio (RQME), R<sub>yy</sub> = Coeficiente de correlação, Bias.

Na tabela 4 os modelos 4 e 5 apresentam resultados superiores aos outros modelos para o coeficiente de correlação igual a 0,9950 e 0,9951 respectivamente. Os modelos 4 e 5 apresentam os menores valores de  $S_{yx}$  %, RQME (12,66; 12,56), (0,2693; 0,2573) enquanto que os modelos 1, 2, 3 os maiores valores.

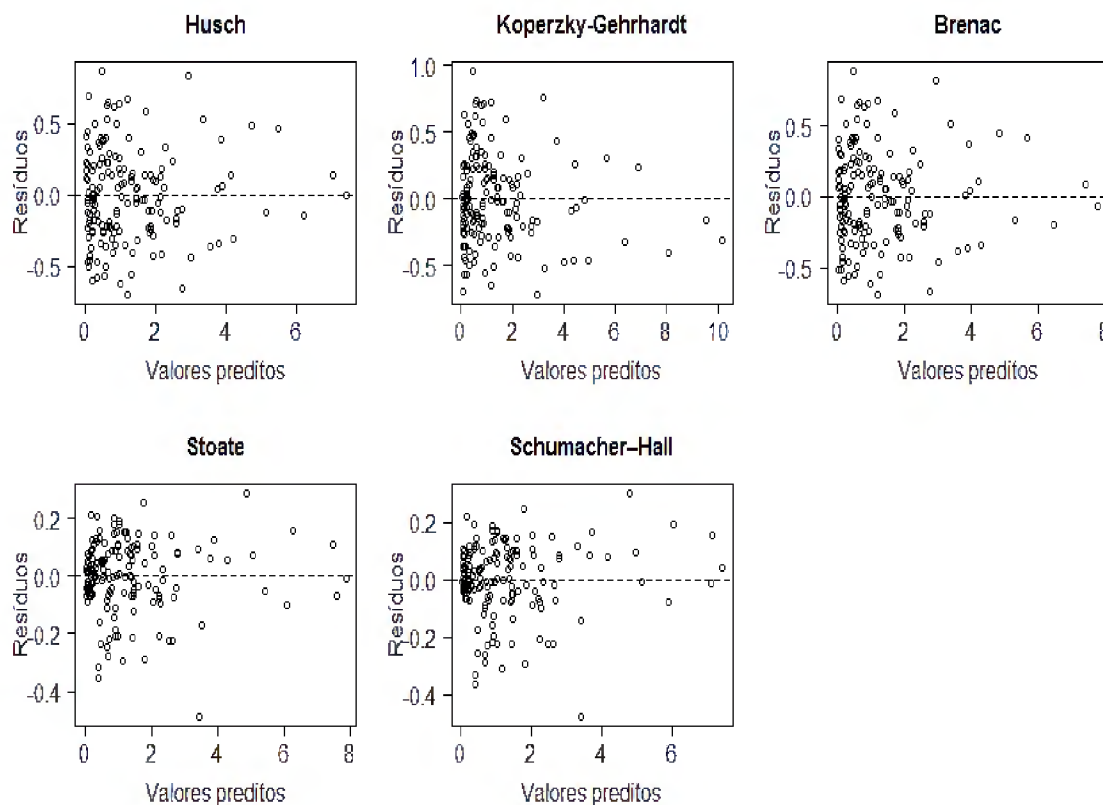
Os modelos 1, 2 e 3 (Koperzky e Gehrhardt, Husch, Brenac) foram os que apresentaram os piores resultados para a estimativa do volume  $m^3$  por apresentarem as métricas dos ajustes.

Os modelos 4 e 5 (Stoate e Schumacher e Hall) obtiveram resultados semelhantes nas métricas do ajuste com uma pequena melhora ao modelo 5 por apresentar melhores resultados para  $Raj^{20}$ %,  $S_{yx}$ % (99,03; 12,56).

Na figura 8 são apresentadas as distribuições de resíduos dos cinco modelos ajustados (Koperzky e Gehrhardt, Husch, Brenac, Stoate e Schumacher e Hall).

Através da análise gráfica de dispersão dos resíduos apresentada da figura 13, verificou-se subestimativa e superestimativa para todos os modelos, como uma melhor distribuição percebida nos gráficos dos modelos 4 e 5.

**Figura 13.** Distribuição dos resíduos em função dos valores preditos, para os cinco modelos ajustados para a fitofisionomia FTFDSM.



### 6.1.3 Transição Cerrado Floresta:

Para o ajuste da fitofisionomia TCF foram utilizadas 110 árvores e para a validação 28 árvores, onde totalizou 138 árvores para essa fitofisionomia. O volume observado foi de 240,429 m<sup>3</sup> com um valor médio 1,742 m<sup>3</sup> por árvore.

**Tabela 5.** Coeficientes e estatísticas de qualidade de ajuste dos modelos de regressão para a fitofisionomia TCF, na Floresta Estadual do Amapá.

Mod	b0	b1	b2	b3	R <sup>2</sup> aj%	S <sub>y,x</sub> %	Bias	RQME	R <sub>ŷy</sub>
1	-8,0630	2,2538			91,10	34,77	0.13582	0.8339	0.9544
2	-4,1515	0.3182			89,57	37,64	0.15794	1.0196	0.9464
3	-11,0275	3,9837	-0.2472		91,38	34,22	0.13316	0.7648	0.9559
4	-10,3513	-0.0854	1,29451	0.43132	98,17	15,74	0.03683	0.3716	0.9908
5	-9,3416	1,9880	0.87327		98,20	15,63	0.02482	0.3642	0.9909

Onde: b0, b1, b2, b3 = coeficientes  $R_{aj}^2\%$  = Coeficiente de determinação ajustado;  $S_{y,x}\%$  = erro padrão de estimativa; Raiz do erro quadrático médio (RQME),  $R_{\hat{y}y}$  = Coeficiente de correlação.

Na tabela 5 os modelos 4 e 5 apresentam os melhores resultados, sendo superiores aos outros modelos para o coeficiente de correlação igual a 0,9908 e


0,9909 respectivamente. Os modelos 4 e 5 apresentaram os menores valores de Syx% e RQME (15,74; 15,63), 0,3716; 0,3642), enquanto que os modelos 1, 2 e 3 os maiores valores para essas métricas.

Os modelos 1, 2 e 3 (Koperzky e Gehrhardt, Husch, Brenac) foram os que apresentaram os piores resultados para a estimativa do volume  $m^3$ .

Os modelos 4 e 5 (Stoate e Schumacher e Hall) obtiveram resultados semelhantes nas métricas do ajuste com uma pequena melhora ao modelo 5 por apresentar melhores resultados para  $Raj^{20\%}$ , Syx% com (98,20; 15,93).

Através da análise gráfica da figura 14 que apresenta os gráficos de dispersão dos resíduos, verificou-se superestimativa e subestimativa nos gráficos dos modelos 1, 2 e 3. Os modelos 4 e 5 foram quais obtiveram melhor distribuição em função da reta.

**Figura 14.** Distribuição dos resíduos em função dos valores preditos, para os cinco modelos ajustados para a fitofisionomia TCF



## 6.2 Redes Neurais Artificiais:

Após o treinamento das 50 RNAs para estimativa do volume  $m^3$  de árvores em pé de cada fitofisionomia (FTFBP, FTFSM e TCF) foi selecionado a melhor RNA para cada

conjunto de entrada, conforme a tabela 1, totalizando cinco RNAs para cada fitofisionomia apresentadas duas estruturas nas tabelas 6, 7 e 8:

**Tabela 6.** Características das Redes neurais artificiais treinadas para fitofisionomia FTFDBP, na Floresta Estadual do Amapá.

RNA	TIPO	Arquitetura	Inputs	outputs	Ciclos	R $\hat{y}$	Função de Ativação	
							Oculto	Saída
RNA 4	MLP	1-6-1	<i>DAP</i>	<i>Volume</i>	30000	0,9037	Sigmoidal	Sigmoidal
RNA 10	MLP	2-6-1	<i>DAP;HC</i>	<i>Volume</i>	30000	0,9798	Sigmoidal	Sigmoidal
RNA 1	MLP	2-6-1	<i>LogDAP;LogHC</i>	<i>Volume</i>	30000	0,9761	Sigmoidal	Sigmoidal
RNA 4	MLP	2-6-1	<i>LogDAP ;LogHC</i>	<i>Volume</i>	30000	0,9768	Sigmoidal	Sigmoidal
RNA 1	MLP	3-6-1	<i>DAP;1/DAP;DAP</i>	<i>Volume</i>	30000	0,9244	Sigmoidal	Sigmoidal

**Tabela 7.** Características das Redes neurais artificiais treinadas para fitofisionomia FTFSM, na Floresta Estadual do Amapá.

RNA	TIPO	Arquitetura	Inputs	outputs	Ciclos	R $\hat{y}$	Função de Ativação	
							Oculto	Saída
RNA 8	MLP	1-6-1	<i>DAP</i>	<i>Volume</i>	30000	0,9307	Sigmoidal	Sigmoidal
RNA 6	MLP	2-6-1	<i>DAP;HC</i>	<i>Volume</i>	30000	0,9941	Sigmoidal	Sigmoidal
RNA 7	MLP	2-6-1	<i>LogDAP;LogHC</i>	<i>Volume</i>	30000	0,9862	Sigmoidal	Sigmoidal
RNA 3	MLP	2-6-1	<i>LogDAP ;LogHC</i>	<i>Volume</i>	30000	0,9854	Sigmoidal	Sigmoidal
RNA 10	MLP	3-6-1	<i>DAP;1/DAP;DAP</i>	<i>Volume</i>	30000	0,9619	Sigmoidal	Sigmoidal

**Tabela 8.** Características das Redes neurais artificiais treinadas para fitofisionomia TCF, na Floresta Estadual do Amapá.

RNA	TIPO	Arquitetura	Inputs	outputs	Ciclos	R $\hat{y}$	Função de Ativação	
							Oculto	Saída
RNA 8	MLP	1-6-1	<i>DAP</i>	<i>Volume</i>	30000	0,9196	Sigmoidal	Sigmoidal
RNA 2	MLP	2-6-1	<i>DAP;HC</i>	<i>Volume</i>	30000	0,9766	Sigmoidal	Sigmoidal
RNA 8	MLP	2-6-1	<i>LogDAP;LogHC</i>	<i>Volume</i>	30000	0,9716	Sigmoidal	Sigmoidal
RNA 6	MLP	2-6-1	<i>LogDAP ;LogHC</i>	<i>Volume</i>	30000	0,9762	Sigmoidal	Sigmoidal
RNA 7	MLP	3-6-1	<i>DAP;1/DAP;DAP</i>	<i>Volume</i>	30000	0,9403	Sigmoidal	Sigmoidal

### 6.2.1 Floresta de Terra Firme Densa de Baixo Platô:


**Tabela 9.** Precisão das redes neurais artificiais selecionadas para a estimativa do volume m<sup>3</sup> FTFBP.

RNA	Bias	RQME	Variância	R $\hat{y}$	VARIÁVEL
RNA 4	-4,6078	0,7917	0,6280	0,9037	DAP
RNA 10	-0,0011	0,3575	0,1281	0,9798	DAP; HC
RNA 1	-0,0024	0,3934	0,1550	0,9761	LogDAP; LogHC
RNA 4	-8,2250	0,3865	0,1497	0,9768	LogDAP <sup>2</sup> ; LogHc
RNA 1	-0,0015	0,6889	0,4755	0,9244	DAP; DAP <sup>2</sup> ; 1/DAP

As RNAs que apresentam o melhor resultado de coeficiente de correlação ( $R_{\hat{y}y}$ ) foram (RNA 10 DAP-HC) e (RNA 4 LogDAP<sup>2</sup>-LogHC) respectivamente. Os resultados de RQME, Bias e Variância foram menores. As outras RNAs obtiveram resultados inferiores a essas duas redes com coeficiente de correlação ( $R_{\hat{y}y}$ ) a baixo de 0,92.

Apesar dos resultados muitos semelhantes entre a RNA 10 e 4, foi escolhida a RNA de número 10 como melhor rede, por obter ligeiramente os melhores resultados nas estatísticas de qualidade.

**Figura 15.** Gráfico de distribuição do volume estimado pelo observado m<sup>3</sup> da RNA 7 FTFBP



Na figura 10 e apresentado os volumes estimados pelos observados em m<sup>3</sup> da RNA 10. Nota-se a uma boa distribuição dos volumes em função da linha de ajuste do gráfico.

### 6.2.2 Floresta de Terra Firme Densa de Sub Montana:

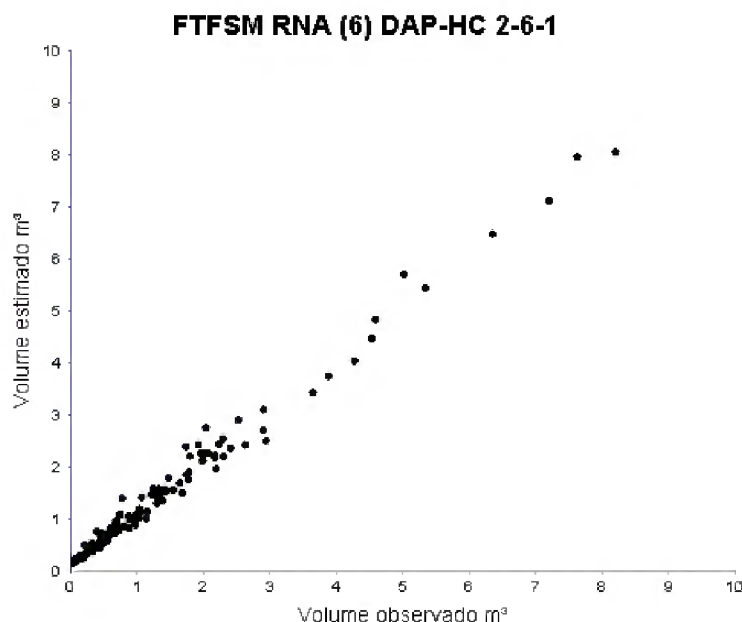
**Tabela 10.** Precisão das redes neurais artificiais selecionadas para a estimativa do volume m<sup>3</sup> FTFDMSM.

RNA	Bias	RQME	Variância	$R_{\hat{y}y}$	VARIÁVEL
RNA 8	9,0352	0,5761	0,3342	0,9307	DAP
RNA 6	4,1846	0,1542	0,0239	0,9941	DAP; HC
RNA 7	-3,5491	0,2511	0,0635	0,9862	LogDAP; LogHC
RNA 3	-0,0041	0,2478	0,0617	0,9854	LogDAP <sup>2</sup> ; LogHc
RNA 10	-2,2953	0,3800	0,1453	0,9619	DAP; DAP <sup>2</sup> ; 1/DAP

Na tabela 10 a RNA que apresentou o melhor resultado de avaliação foi a (RNA 6DAP-HC) respectivamente. Os resultados de Variância e RQME foram menores que as demais redes treinadas. Outra RNA que teve o resultado semelhante foi (RNA 7LogDAP-

LogHC) que obteve  $R_{\hat{y}y}$  de 0,9862. Apesar dos resultados muitos semelhantes entre a RNA 7 e 6, foi escolhida a RNA de número 7 com ligeiramente melhor métrica dos resultados estatísticos.

**Figura 16.** Gráfico de distribuição do volume estimado pelo observado  $m^3$  da RNA 6 FTFSM



Na figura 16 apresenta os volumes estimados  $m^3$  em função do volume observado  $m^3$  da RNA 6 DAP-HC. Nota-se que as dispersões dos volumes seguem a tendência da reta como boa aderência dos dados.

### 6.2.3 Transição Cerrado Floresta:


**Tabela 11.** Precisão das redes neurais artificiais selecionadas para a estimativa do volume  $m^3$  TCF.

RNA	Bias	RQME	Variância	$R_{\hat{y}y}$	VARIÁVEL
RNA 8	-9,6333	0,6439	0,4190	0,9196	DAP
RNA 2	-7,1108	0,3721	0,1397	0,9766	DAP; HC
RNA 8	0,0020	0,3910	0,1543	0,9716	LogDAP; LogHC
RNA 6	-0,0012	0,3560	0,1279	0,9762	LogDAP <sup>2</sup> ; LogHc
RNA 7	0,0010	0,5261	0,2795	0,9403	DAP; DAP <sup>2</sup> ; 1/DAP

A RNA que apresentou o melhor resultado do coeficiente de correlação ( $R_{\hat{y}y}$ ) foi a (RNA 2DAP-HC) em seguida as RNAs (RNA 6 LogDAP<sup>2</sup>; LogHc) e (RNA 8 LogDAP; LogHC). As outras RNAs obtiveram resultados inferiores a essas três RNAs. Apesar

dos resultados muitos semelhantes a RNA 2 DAP-HC foram escolhida como melhor rede por ter as melhores estatísticas de qualidade.

**Figura 17.** Gráfico de distribuição do volume estimado pelo observado m<sup>3</sup> da RNA 2 TCF



Na figura 17 apresenta os volumes estimados pela melhor RNA em função do volume observado. Nota-se que as dispersões dos volumes seguem a tendência da reta como boa aderência dos dados a RNA 5 DAP-HC.

### 6.3 Avaliação dos melhores modelos matemáticos e RNAs

Para análise foi reunido na tabela 12 os Coeficientes de Correlação ( $R^2$ ), Raiz do Erro Quadrático Médio (RQME) e Bias das melhores RNAs treinadas e melhores modelos matemáticos ajustados para cada fitofisionomia.

**Tabela 12.** Resultado dos parâmetros estatísticos das RNAs e modelos matemáticos para estimativa do volume nas fitofisionomias FTFDBP, FTFDSM e TCF.

Parâmetros	FTFDBP		FTFDSM		TCF	
	Schumacher-Hall	RNA10	Schumacher-Hall	RNA6	Schumacher-Hall	RNA2
$R^2$	0,9889	0,9798	0,9951	0,9941	0,9909	0,9766
Bias	0,0393	-0,0011	0,01712	4,1846	0,02482	-7,1108
RQME	0,4040	0,3575	0,2573	0,1542	0,2573	0,3721

FTFDBP= Floresta de Terra Firme de Baixo Plato; FTFDSM= Floresta de Terra Firme de Sub Montana; TCF= Transição Cerrado Floresta.



Na tabela 12 observa se os valores de coeficiente de correlação ( $R^2$ ) variando de 0,9766 a 0,9951 para as RNAs e modelos matemáticos, esses resultados são bastante próximos, havendo pouca diferença entre os modelos matemáticos e as redes neurais artificiais.

Os resultados obtidos nas estimativas dos volumes para a fitofisionomia FTFBP com os dois métodos, RNA 10 e modelo de Schumacher-Hall foram bastante semelhantes, com os coeficientes de correlação ( $R^2$ ) em torno de (0,9798; 0,9889) e a raiz do erro quadrático médio (RQME) (0,3575). Os resultados obtidos como modelo de Schumacher-Hall, no entanto, foram ligeiramente melhores. Ribeiro et al (2016) aplicando redes neurais artificiais e modelos volumétricos para estimar o volume de árvores na Floresta Nacional do Tapajós obtiveram resultados semelhantes, porém as RNAs foram ligeiramente melhores que os modelos matemáticos.

Os resultados obtidos nas estimativas dos volumes para fitofisionomia FTFSM foram de 0,9941 para o coeficiente de correlação ( $R^2$ ) da RNA 6 e 0,9951 para o coeficiente de correlação do modelo de Schumacher-Hall.

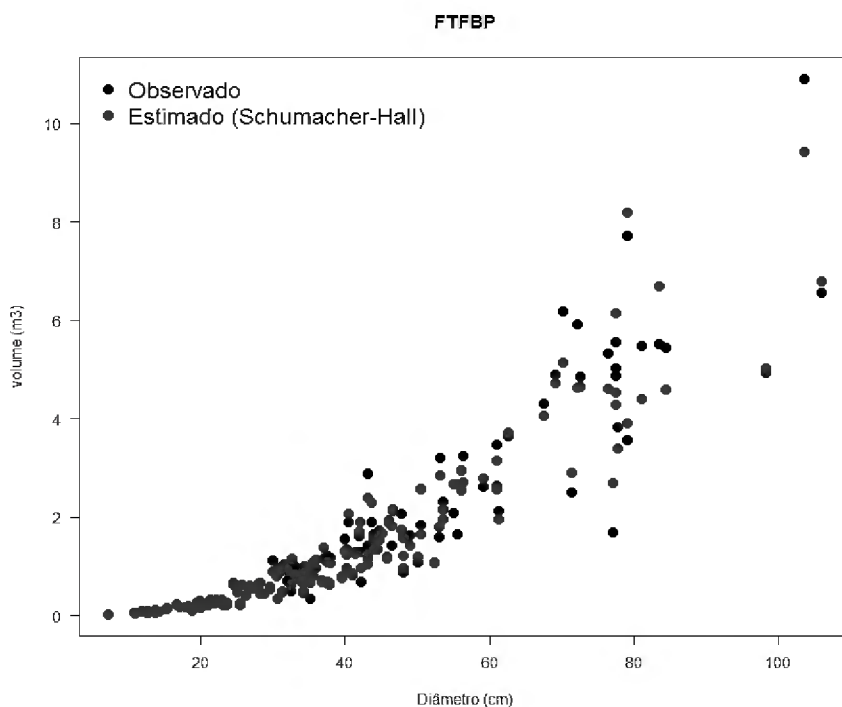
Os resultados para essa fitofisionomia foram bastante semelhantes, levando em consideração a raiz do erro quadrático médio RQME a RNA 6 foi a que apresentou os melhores resultados. Rodrigues et al (2010) ao realizar estimativas volume comercial do *Schizolobium amazonicum* (Huber) Ducke, com casca, utilizando Redes Neurais Artificiais (RNAs) de múltiplas camadas e comparando com modelos matemáticos ajustados pelo método de regressão linear, verificou se que as RNAs obtiveram melhores resultados em comparação aos modelos de regressão, o erro padrão da estimativa foi cerca de 30% menor do que obtidos pelos pela análise de regressão. Abreu et al (2017) ao comparar redes neurais artificiais com modelos matemáticos para estimar o volume de árvores de uma floresta nativa Estacional Semidecidual, obteve resultados superiores com as RNAs em relação aos modelos matemáticos.

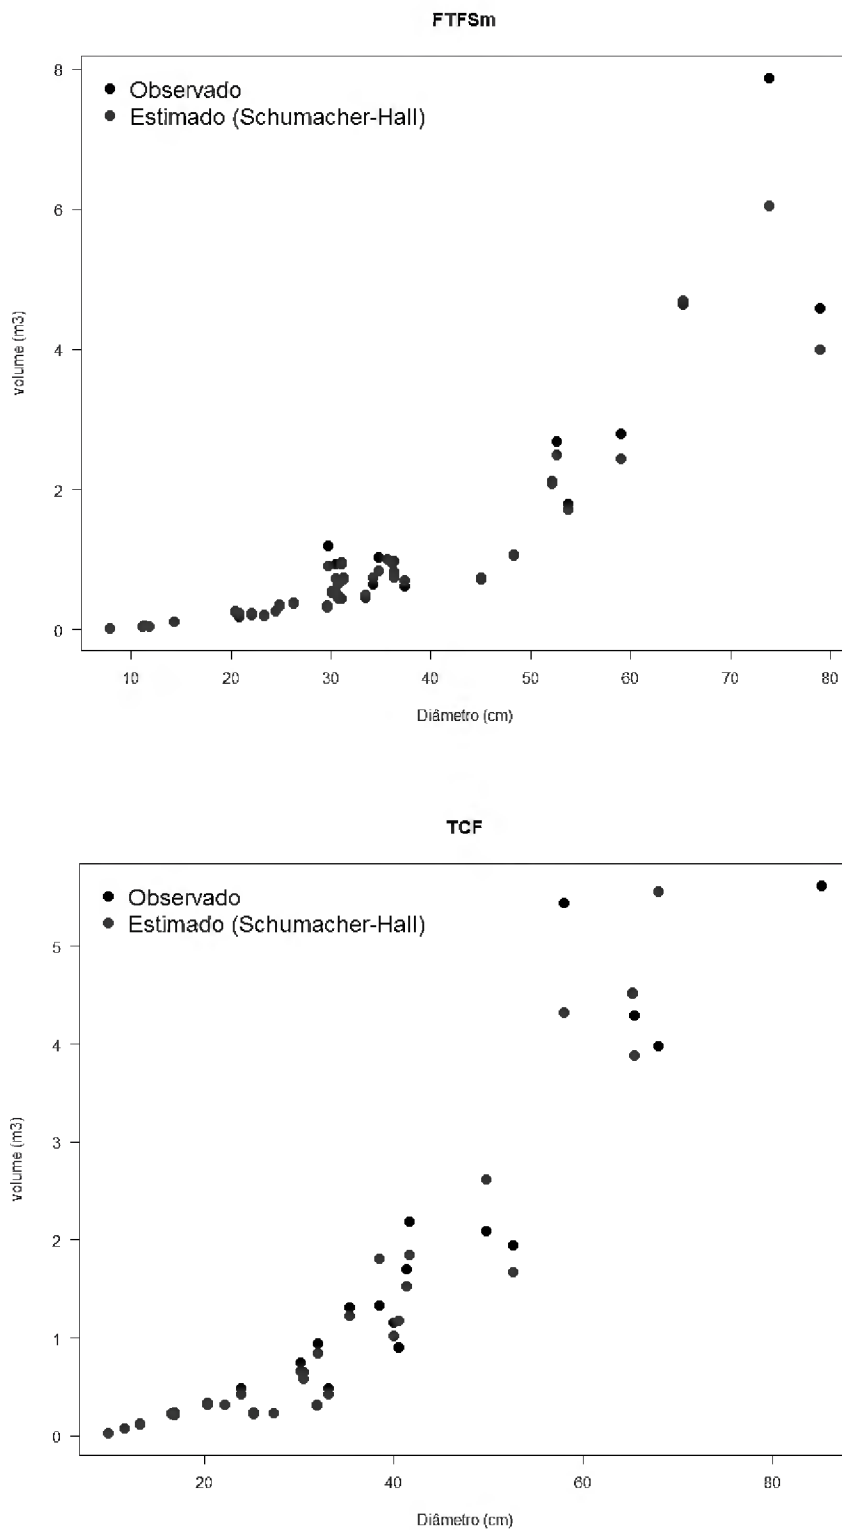
Os resultados obtidos neste trabalho na estimativa dos volumes na fitofisionomia TCF foram bastantes semelhantes com a RNA 2 e com o modelo de Schumacher-Hall com  $R^2$  (0,9909 e 0,9766, respectivamente). Esses resultados corroboram com os resultados obtidos por Lacerda et al (2017) que ao utilizar redes neurais artificiais e modelos matemáticos para estimar o volume de árvores de uma floresta natural de savana, mostrou que os resultados com dois métodos de estimativa foram bastante semelhantes. Os resultados das Bias foram também bastantes semelhantes aos dois métodos de estimativa para fitofisionomia TCF.

#### 6. 4 Validação dos melhores modelos matemáticos e RNAs:

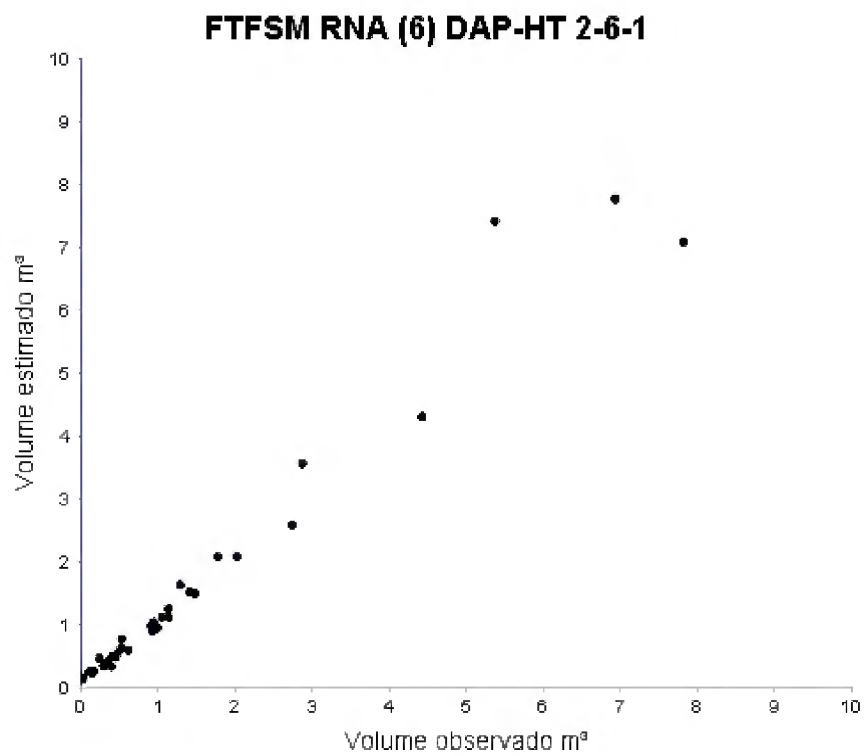
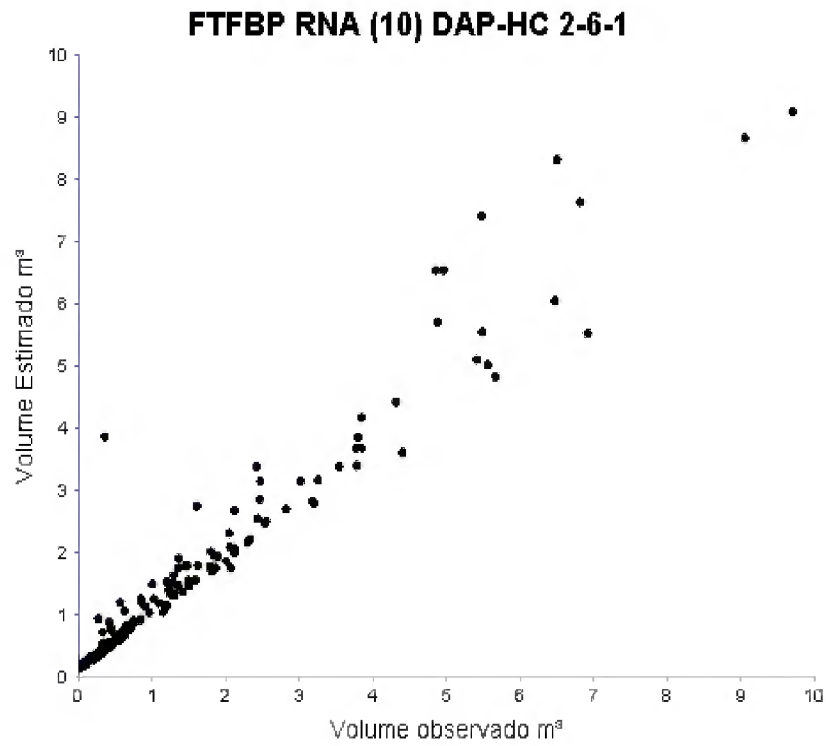
Para realizar a validação foi separado aleatoriamente 20 % dos dados de cada fitofisionomia (FTFBP, FTFSM e TCF), e depois feita a generalização dos dados para os melhores modelos e melhores RNAs. Na Figura 18 a generalização dos modelos matemáticos com os 20% dos dados separados aleatoriamente mostra-se com boa distribuição para a fitofisionomia FTFBP, FTFSM e TCF com dispersão dos dados pouco acentuada. Isso demonstra o poder de generalização dos modelos e a capacidade de aplicarmos no setor florestal.


**Figura 18.** Gráfico de distribuição do volume estimado e observado dos modelos matemáticos selecionados para a FTFBP , FTFSM e TCF com 20% dados de validação





**Figura 19.** Gráfico de distribuição do volume estimado pelo observado das RNAs 10 DAP-HC, 6 DAP-HC, 2 DAP-HC selecionadas para a FTFBP, FTFSM e TCF com 20% dados de validação





Na figura 19 a generalização das RNAs com os 20% dos dados separados aleatoriamente revela boa distribuição dos dados para fitofisionomia FTFBP. Para as fitofisionomias FTFSM e TCF os dados se mostraram altamente aderentes à reta do gráfico, com pouca dispersão. Vale destacar que, de acordo com Pandorfietta. (2011), um dos problemas no treinamento da rede neural tipo MultilayerPerceptron (MLP) com treinamento backpropagation é a definição de seus parâmetros. A seleção dos parâmetros de treinamento do algoritmo é um processo que demandou grande esforço, pois pequenas diferenças nesses parâmetros levaram a grandes alterações, tanto no tempo de treinamento como na generalização obtida. Por isso vale ressaltar importância de sempre se testar novas arquiteturas de redes neurais artificiais para conseguir RNAs com parâmetros estatísticos satisfatórios. Segundo Binoti et al. (2009), a obtenção da arquitetura adequada da rede neural depende de inúmeras tentativas, a fim de gerar resultados satisfatórios, uma vez que esse processo é aleatório, ou seja, o número de neurônios por camadas não se baseia em nenhum critério, apenas em tentativa.

## 7 CONCLUSÕES

1. A utilização de RNA como metodologia para estimativa de volume de árvores em pé proposta neste estudo apresentou resultados bastante semelhantes às estimativas obtidas por regressão linear.
2. Considerando as estatísticas de qualidade de ajuste e os gráficos de dispersão (volume observado pelo estimado), a RNA com arquitetura 2-6-1, com variáveis de entrada Dap e Hc, algoritmo de treinamento da rede MLP (*Backpropagation*), com 30000 ciclos e função de ativação sigmoidal, mostrou-se superior aos demais métodos de estimativa do volume para as três fitofisionomias estudadas.
3. As RNAs com a variável 'Dap' e HC transformada (LogDAP, LogDAP<sup>2</sup>, LogHC na camada de entrada também apresentaram estatísticas satisfatórias.
4. O modelo de regressão proposto de Schumacher e Hall ajustaram se bem aos dados, podendo ser utilizado para estimar o volume de árvores em pé na Floresta Estadual do Amapá em suas três fitofisionomias FTFDBP, FTFDSM E TCF.

## 8 REFERÊNCIAS BIBLIOGRÁFICAS

- ABREU, J. C.; SOARES, C. P. B.; LEITE, H. G. Assessing Alternativesto Estimatem Volume of a Seasonal Semi-Deciduous Forest. **RevistaFloresta**, 47(4), 375-382. 2017.
- ALMEIDA, A. C.; BARROS, P. L.; MONTEIRO, J. H.; ROCHA, B. R. Estimativa de biomassa arbórea: uma comparação entre métodos estatísticos e redes neurais. **Encontro de Energia no Meio Rural**, pag.6. 2006.
- 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** (Brazilian Journal of Wood Science), 5(1), 10-12953, 2014.
- BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G.; ARAÚJO, L. S. A.; ALBUQUERQUE, A. C. Modelagem da distribuição de diâmetros utilizando autômatos celulares e redes neurais artificiais. **Revista Cerne**, 19(4), 2013.
- BINOTI, M. L. M. S. **Emprego de redes neurais artificiais em mensuração e manejo florestal**. Tese (Doutorado em Ciência Florestal) Universidade Federal de Viçosa, Viçosa, MG. 130pag. 2012.
- BINOTI, M. L. M. S.; BINOTI, D. H. B.; GLERIANI, J. M.; LEITE, H. G. Ajuste do modelo de Schumacher 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.
- BRAGA, A. D. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Fundamentos de redes neurais artificiais**. Rio de Janeiro: 11a Escola de Computação, 1998.
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. UFV, Viçosa, MG: Universidade Federal de Viçosa. 543p. 2013.
- CARDON, A.; MULLER, D. N.; NAVAUUX, P. **Introdução às redes neurais artificiais**. Instituto de Informática. Universidade Federal do Rio Grande do Sul. (1994).
- CHURCHLAND, P. S.; SEJNOWSKI, T. J. **The computation albrain**. Cambridge: Mit Press Cambridge, 1994
- FERNEDA, E. **Redes neurais e sua aplicação em sistemas de recuperação de informação**. Ciência da Informação, 35(1) 2006.
- FINGER, C. A. G. **Fundamentos de biometria florestal**. Santa Maria: UFSM/CEPEF/FATEC, 269 p, 1992.
- HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001.
- HORKIN, K; STINCHCOMBE, M; WHITE, H. **Multilayer feed foward network are universal approximators**. Neural Networks, Bandera, v.2, n.5, p. 359-366, 1989.
- HICKEY, C.; KELLY, S.; CARROLL, P.; O'CONNOR, J. Prediction of Forestry Planned End Products Using Dirichlet Regression and Neural Networks. **Forest Science**, 61(2), 289-297, 2015.
- HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001.

HAYKIN, S. **Neural networks: a comprehensive foundation**. New York: Cambridge University Press, 1999.

HIGUCHI, N.; SANTOS, J.; LIMA, A. J. N. **Biometria Florestal**. Instituto Nacional de Pesquisas da Amazônia / Coordenação de Pesquisas em Silvicultura Tropical - Laboratório de Manejo Florestal – LMF/ Manaus, AM, 141 p, 2008.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Manual Técnico da Vegetação Brasileira. 2ª Ed.** Rio de Janeiro, RJ – Brasil, 271p. 2012.

INSTITUTO ESTADUAL DE FLORESTAS DO AMAPÁ, **Resumo do Inventário Florestal da Floresta Estadual do Amapá**. Relatório. 39p. 2016.

LACERDA, T. H. S.; CABACINHA, C. D.; ARAÚJO, J. C. A.; MAIA, R. D.; LACERDA, K. W. D. S. Artificial Neural Networks for Estimating Tree Volume in the Brazilian Savanna. **Revista Cerne**, 23(4), 483-491. 2017.

LASTIRI, C. P.; PAULETTI, R. M. O. **Aplicação de Redes Neurais Artificiais à Engenharia de Estruturas**. XXXI Jornadas Sud-Americanas de Ingenieria Estructural, Mendoza, Argentina, 2004.

LEITE, H. G.; REGAZZI, A. J. Métodos estatísticos para avaliar a igualdade de equações. Viçosa-MG, **Revista Árvore**, v16, n.1, p.59-71, 1992.

LEITE, H. G.; ANDRADE, V. C. L.; Um método para condução de inventários florestais sem o uso de equações volumétricas. **Revista Árvore**, Viçosa-MG, v.26, n.3, p.321-328, 2002.

LEAL, F. A.; MIGUEL, E. P.; MATRICARDI, E. A. T.; PEREIRA, R. S. Redes neurais artificiais na estimativa de volume em um plantio de eucalipto em função de fotografias hemisféricas e número de árvores. **Revista Brasileira de Biometria**, São Paulo, v.33, n.2, p.233-249, 2015.

MOREIRA, E. S. Os neurônios, as sinapses, o impulso nervoso e os mecanismos morfo-funcionais de transmissão dos sinais neurais do sistema nervoso. **Coleção Monográfica Neuroanatomias Morfo funcionais**. UniFOA, Volta Redonda, Rio de Janeiro, 2017.

NISHIDA, S. M. **Mecanismos de comunicação entre os neurônios e dos Neurônios com os órgãos efetadores**. Departamento de Fisiologia, IB Unesp – Botucatu, São Paulo. 2007.

ÖZÇELİK, R.; DIAMANTOPOULOU, M. J.; EKER, M.; GÜRLEVIK, N. Artificial Neural Network Models: An Alternative Approach for Reliable Aboveground Pine Tree Biomass Prediction. **Forest Science**, 63(3), 291-302, 2017.

PANDORFI, N.; SILVA, I. J. O.; SARNIGHAUSEN, V. C. R.; VIEIRA, F. M. C.; NASCIMENTO, S. T.; GUISELINI, C. Uso de redes neurais artificiais para predição de índices zootécnicos nas fases de gestação e maternidade na suinocultura. **Revista Brasileira de Zootecnia**, v.40, n.3, p.676-681, 2011.

R CORE TEAM R: **A languagean denvironment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>, 2017.



RIBEIRO, R. B.; GAMA, J. R. V.; SOUZA, A. L.; LEITE, H. G.; SOARES, C. P. B.; SILVA, G. F. Métodos para estimar o volume de fustes e galhos na floresta nacional do tapajós. **Revista Árvore**, 40(1), 81-88, 2016.

RODRIGUES, E. F.; OLIVEIRA, T. F.; MADRUGA, M. R.; SILVEIRA, A. M. A method for determining the commercial volume of the *schizolobium amazonicum (huber)* ducke using artificial neural networks. **Rev. Brasileira de Biometria**, São Paulo, v.28, n.1, p.16-23, 2010.

ROLIM, S. G.; COUTO, H. D.; JESUS, R. D.; FRANÇA, J. T. Modelos volumétricos para a Floresta Nacional do Tapirapé-Aquirí, Serra dos Carajás (PA). **Revista Acta Amazônica**, 36(1), 107-14, 2006.

SANQUETTA, C. R.; WATZLAWICK, L. F.; CORTÊ, A. P. D.; FERNANDES, L. D. A.; SIQUEIRA, J. D. P. **Inventários florestais: planejamento e execução**. Curitiba: Multi-Graphic, 2. 2009.

SCHOENINGER, E.R. **Uso de redes neurais artificiais para mapeamento de biomassa e carbono orgânico no componente arbóreo de uma Floresta Ombrófila Densa**. Tese (Doutorado em Ciências Florestais) – Universidade Federal do Paraná, Curitiba, 146f.2006.

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

SCOLFORO, J. R. S. **Biometria florestal 2: Técnica de regressão aplicada para estimar: volume, biomassa, relação hipsométrica e múltiplos produtos de madeira**. Lavras: UFLA/FAEPE, 292 p, 1997.

SCHNEIDER, P. R. **Introdução ao Manejo florestal**. Santa Maria: Ed. UFSM, 1993. 348 p.

SILVA, J. N. M. **Manejo florestal**. Brasília, DF: EMBRAPA-SPI; Belém, PA: EMBRAPA-CPATU, 1996., 2001.

SILVA, I. N.; SPATTI, D. H; FLAUZINO, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas: curso prático**. 399 p Ed Artliber - SP, Universidade de São Paulo. 2010.

SIMÕES, M. G., SHAW, I. S. **Controle e modelagem fuzzy**. Blucher: FAPESP, São Paulo, BRA. 2007.

STEPKA, T. F. **Modelagem do crescimento e dendrocronologia em árvores nativas de Araucaria angustifolia, Cedrela fissilis e Ocotea porosa no sul do Brasil**. Tese de Doutorado. Universidade Federal de Paraná. Curitiba-PR, 208p. 2012.

SOUZA, E. D.; CUNHA, A. D. **Climatologia de precipitação no Amapá e mecanismos climáticos de grande escala**. Projeto REMETAP no Estado do Amapá, Macapá - AP: IEPA, 177-195. 2010.

THAINES, F.; BRAZ, E. M.; MATTOS, P. P.; THAINES, A. A. R. Equações para estimativa de volume de madeira para a região da bacia do Rio Ituxi, Lábrea, AM. **Revista Pesquisa Florestal Brasileira**, 30(64), 283, 2010.

