

**UNIVERSIDADE FEDERAL DOS VALES DO
JEQUITINHONHA E MUCURI - UFVJM**

BRUNO OLIVEIRA LAFETÁ

**EFICIÊNCIA NUTRICIONAL, ÁREA FOLIAR E PRODUTIVIDADE DE
PLANTAÇÕES DE EUCALIPTO EM DIFERENTES ESPAÇAMENTOS
ESTIMADOS COM REDES NEURAS ARTIFICIAIS**

DIAMANTINA

MINAS GERAIS - BRASIL

2012

BRUNO OLIVEIRA LAFETÁ

**EFICIÊNCIA NUTRICIONAL, ÁREA FOLIAR E PRODUTIVIDADE DE
PLANTAÇÕES DE EUCALIPTO EM DIFERENTES ESPAÇAMENTOS
ESTIMADOS COM REDES NEURAIS ARTIFICIAIS**

Dissertação apresentada à Universidade Federal dos Vales do Jequitinhonha e Mucuri, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, área de concentração em Silvicultura e Manejo Florestal, para a obtenção do título de Mestre.

Orientador: Prof. Dr. Reynaldo Campos Santana

Co-orientador: Prof. Dr. Gilciano Saraiva Nogueira

DIAMANTINA

MINAS GERAIS - BRASIL

2012

Ficha Catalográfica - Serviço de Bibliotecas/UFVJM
Bibliotecária Viviane Pedrosa
CRB6-2641

L162e Lafeté, Bruno Oliveira
2012 Eficiência nutricional, área foliar e produtividade de plantações de eucalipto em diferentes espaçamentos estimados com redes neurais artificiais. – Diamantina: UFVJM, 2012.
76f.

Orientador: Prof. Dr. Reynaldo Campos Santana
Co-orientador: Prof. Dr. Gilciano Saraiva Nogueira

Dissertação (Mestrado em Ciência Florestal) - Faculdade de Ciências Agrárias, Universidade Federal dos Vales do Jequitinhonha e Mucuri.

1. CUB 2. RNA 3. Amostragem não destrutiva 4. Prognose I. Título.

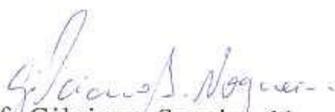
CDD 634.9

**EFICIÊNCIA NUTRICIONAL, ÁREA FOLIAR E PRODUTIVIDADE
DE PLANTAÇÕES DE EUCALIPTO EM DIFERENTES
ESPAÇAMENTOS ESTIMADOS COM REDES NEURAIAS
ARTIFICIAIS**

Bruno Oliveira Lafetá

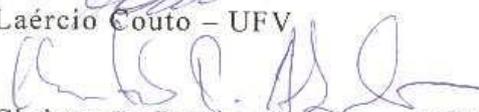
Dissertação apresentada ao Programa de Pós-Graduação em Ciência Florestal, nível de Mestrado, como parte dos requisitos para obtenção do título de Mestre.

APROVADA EM 29 / 02 / 2012


Prof. Gilciano Saraiva Nogueira – UFVJM
Co-Orientador


Prof. Júlio César Lima Neves – UFV


Prof. Laércio Couto – UFV


Prof. Christovão Pereira Abrahão – UFVJM


Prof. Reynaldo Campos Santana – UFVJM
Presidente

DIAMANTINA
2012

DEDICO:

À Deus, pela força e oportunidade nos estudos e pesquisas.

À minha avó Maria das Mercês por todo carinho e amor.

*À minha tia Terezinha por estar sempre do meu lado me defendendo
e apoiando em todas as dificuldades.*

À minha família, especialmente aos meus pais

*Luiz Fernando e Célia, pelo amor, apoio e ensinamentos
para a realização dos meus sonhos.*

*À minha irmã pela sua presença nos momentos mais importantes
durante minha vida.*

AGRADECIMENTOS

Agradeço a Deus por me proporcionar estudo, força e paciência para conquista de mais uma etapa em minha vida, o mestrado.

À minha família, Luiz Fernando (pai), Célia (mãe), Mariana (irmã) e a minha tia Terezinha, por todo amor e apoio, fundamentais na estruturação da minha vida acadêmica. Amo vocês.

Ao professor Dr. Reynaldo Campos Santana pelo incentivo, conhecimento proporcionado, amizade e orientação em todo o trabalho de pesquisa.

Aos meus colegas pelos laços de amizade e por todos os momentos de harmonia e dedicação, que nos tornaram uma grande família.

Aos professores e funcionários da Universidade Federal dos Vales do Jequitinhonha e Mucuri e Universidade Federal de Viçosa por toda assistência e paciência.

À Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão de bolsa de estudos e pela realização da mobilidade acadêmica entre os Programas de Pós-graduação em Solos e Nutrição de Plantas da Universidade Federal de Viçosa – UFV e o de Ciência Florestal da Universidade Federal dos Vales do Jequitinhonha e Mucuri – UFVJM, via Programa Nacional de Cooperação Acadêmica (Procad).

Ao professor Dr. Júlio César Lima Neves pela assistência e orientação ao longo da mobilidade acadêmica na Universidade Federal de Viçosa.

Ao Conselho Nacional de Pesquisa e Desenvolvimento Científico e Tecnológico (CNPq) pela concessão de bolsa de estudos.

À Aperam Bioenergia, antiga ACESITA, à Agência Nacional de Energia Elétrica (ANEEL) e à Cemig pelo apoio a pesquisa.

Ao Marcelo Dias Müller e toda a equipe responsável pela instalação do experimento, propiciando o desenvolvimento deste trabalho.

Em especial, ficam meus agradecimentos a Eliseu, Henrique, Tamires, Walmir e Gustavo, que sempre me estenderam a mão nos momentos de dificuldade, amigos que valorizo muito!

À todas as pessoas que, de alguma forma, contribuíram para realização deste trabalho.

BIOGRAFIA

BRUNO OLIVEIRA LAFETÁ, filho de Luiz Fernando Alves e Lafetá e Célia Souza Oliveira Lafetá, natural de Montes Claros, Minas Gerais, nasceu no dia 16 de fevereiro de 1987.

Em agosto de 2005, iniciou o curso de graduação em Engenharia Florestal pela Universidade Federal dos Vales do Jequitinhonha e Mucuri, o qual concluiu em dezembro de 2009.

Em março de 2010, ingressou no Programa de Pós-Graduação em Ciência Florestal pela Universidade Federal dos Vales do Jequitinhonha e Mucuri.

No período de agosto a dezembro de 2010, realizou treinamento, como mobilidade acadêmica, no Departamento de Solo da Universidade Federal de Viçosa.

Em fevereiro de 2012, defendeu a dissertação de mestrado.

RESUMO

O emprego de práticas silviculturais apropriadas associado ao uso de métodos de avaliação nutricional e técnicas estatísticas avançadas pode ser uma alternativa viável no estabelecimento de critérios práticos de caracterização e classificação nutricional, além de permitir obter informações sobre a dinâmica de crescimento dentro de povoamentos florestais, enriquecendo estudos sobre a sustentabilidade e produção de um ecossistema florestal. O presente trabalho foi dividido em três capítulos. Os objetivos foram avaliar os coeficientes de utilização biológicos (CUB's) dos nutrientes pelo eucalipto, a eficiência e possibilidade de utilização das redes neurais artificiais (RNA) para obter os CUB's e estimativas para a biomassa de tronco sob diferentes espaçamentos. O experimento foi instalado em dezembro de 2002 utilizando-se um híbrido de *Eucalyptus grandis* W. Hill ex Maiden x *Eucalyptus camaldulensis* Dehnh sobre Latossolo Vermelho-Amarelo em relevo plano a 1097 m altitude. Adotou-se o delineamento em blocos ao acaso sendo estudado, em três blocos, o efeito de cinco espaçamentos de plantio: T1 - 3,0 x 0,5 m; T2 - 3,0 x 1,0 m; T3 - 3,0 x 1,5 m; T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m. Realizou-se o inventário florestal contínuo nas idades de 48, 61, 73, 85 e 101 meses. Em cada árvore-amostra por unidade experimental na última idade foram: quantificada a biomassa; mensurada a área e perímetro foliar, área foliar específica e realizada a análise química de N, P, K, Ca, Mg e S para amostras composta (ao longo do fuste) e simples (região do DAP) dos componentes. Os resultados foram submetidos à ANOVA, regressão e a aplicação das RNA. A modelagem por redes neurais artificiais demonstrou-se adequada para estimar a produção de biomassa de tronco em função da idade sob diferentes espaçamentos, utilizando o *DAP* e perímetro foliar como variáveis preditoras. Não houve grande variação da eficiência de uso dos nutrientes entre os espaçamentos, principalmente para o tronco. A rede neural artificial foi eficiente em estimar a eficiência de uso dos nutrientes. A modelagem por redes neurais artificiais utilizando-se apenas amostra da casca na região do *DAP* demonstrou ser adequada para a estimativa do coeficiente de utilização biológico do tronco.

Palavras-chave: CUB; RNA; Amostragem não destrutiva; Prognose.

ABSTRACT

The use of appropriate silvicultural practices associated with the use of methods of nutritional assessment and advanced statistical techniques can be a viable alternative to establish practical criteria characterization and classification of nutritional status, and allows information on the dynamics of growth in forest stands, enriching studies on the sustainability and production of a forest ecosystem. This work was divided into three chapters. The objectives were assess the coefficient of biological use (CUB's) of nutrients by eucalyptus trees, the efficiency and possible use of artificial neural networks (RNA) for the CUB's and biomass trunk under different spacings. The research plots was installed in december 2002 using a hybrid of *Eucalyptus grandis* W. Hill ex Maiden X *Eucalyptus camaldulensis* Dehnh. The statistical design was randomized blocks being studied, in three blocks, the effect of different planting spacings: T1 – 3,0 x 0,5 m, T2 – 3,0 x 1,0 m, T3 – 3,0 x 1,5 m, T4 – 3,0 x 2,0 m e T5 – 3,0 x 3,0 m. Data collection was carried out at ages 48, 61, 73, 85 and 101 months. In each sample-tree per experimental unit in the last age were: quantified biomass; measured leaf area, leaf perimeter, specific leaf area and chemical analysis of N, P, K, Ca, Mg and S for composite samples (along the stem) and simple samples (the region of the DAP) of components. Statistical analysis of the data consisted of ANOVA, regression and application of RNA. The modeling by artificial neural networks demonstred to be adequate to estimate the biomass of the trunk in relation to age at different spacings, using the DBH and perimeter leaf as predictors variables. There wasn't wide variation in efficiency use nutrient among spacings, especially for the trunk. The artificial neural network was effective in estimating the efficiency of nutrient use. The modeling by artificial neural networks using only sample in the DAP region proved to be adequate for estimating the coefficient of biological use of stem.

Key words: CUB; RNA; Non-destructive sampling; Prediction.

SUMÁRIO

RESUMO	vii
ABSTRACT	viii
LISTA DE TABELAS	xi
LISTA DE FIGURAS	xiii
INTRODUÇÃO GERAL	15
REFERÊNCIAS BIBLIOGRÁFICAS	17
CAPÍTULO 1 – MODELAGEM ECOFISIOLÓGICA POR REDES NEURAIS ARTIFICIAIS PARA DIFERENTES ESPAÇAMENTOS EM EUCALIPTO.....	18
RESUMO	18
ABSTRACT	19
1. INTRODUÇÃO	20
2. MATERIAL E MÉTODOS	21
3. RESULTADOS E DISCUSSÃO	24
4. CONCLUSÃO	33
5. REFERÊNCIAS BIBLIOGRÁFICAS	33
CAPÍTULO 2 – EFICIÊNCIA DE USO DE NUTRIENTES EM EUCALIPTO SOB DIFERENTES ESPAÇAMENTOS AVALIADOS POR MÉTODOS TRADICIONAIS E POR REDES NEURAIS ARTIFICIAIS.....	36
RESUMO	36
ABSTRACT	37
1. INTRODUÇÃO	38
2. MATERIAL E MÉTODOS	40
3. RESULTADOS E DISCUSSÃO	43
4. CONCLUSÕES	53
5. REFERÊNCIAS BIBLIOGRÁFICAS	53

CAPÍTULO 3 – EFICIÊNCIA DE UTILIZAÇÃO DE MACRONUTRIENTES EM EUCALIPTO POR MÉTODO NÃO DESTRUTIVO ESTIMADOS POR REDES NEURAS ARTIFICIAIS.....	57
RESUMO	57
ABSTRACT	58
1. INTRODUÇÃO	59
2. MATERIAL E MÉTODOS	61
3. RESULTADOS E DISCUSSÃO	64
4. CONCLUSÃO	71
5. REFERÊNCIAS BIBLIOGRÁFICAS	71
CONCLUSÕES GERAIS	74
APÊNDICE	75

LISTA DE TABELAS

CAPÍTULO 1 – MODELAGEM ECOFISIOLÓGICA POR REDES NEURAIAS ARTIFICIAIS PARA DIFERENTES ESPAÇAMENTOS EM EUCALIPTO

Tabela 1. Sequência implantada na seleção das redes neurais artificiais	24
Tabela 2. Correlações de Pearson entre diâmetro a 1,30 m de altura (<i>DAP</i>) e altura total (<i>Ht</i>) com área foliar (<i>AF</i>), perímetro foliar (<i>P</i>) e área foliar específica (<i>AFE</i>)	26
Tabela 3. Características das redes neurais artificiais (RNA) selecionadas para projetar a biomassa de lenho	28
Tabela 4. Precisão das redes neurais artificiais (RNA)	29

CAPÍTULO 2 – EFICIÊNCIA DE USO DE NUTRIENTES EM EUCALIPTO SOB DIFERENTES ESPAÇAMENTOS AVALIADOS POR MÉTODOS TRADICIONAIS E POR REDES NEURAIAS ARTIFICIAIS

Tabela 1. Resumo da análise de variância da biomassa, volume e coeficiente de utilização biológico (CUB) por macronutriente e componente	47
Tabela 2. Estatísticas dos ajustes realizados para estimação do volume, da biomassa e do coeficiente de utilização biológico (CUB) a partir da distância entre plantas	48
Tabela 3. Características das redes neurais artificiais (RNA) selecionadas para projetar o coeficiente de utilização biológico no tronco (CUB_{Tronco})	52
Tabela 4. Precisão das redes neurais artificiais (RNA) para cada macronutriente	52

CAPÍTULO 3 – EFICIÊNCIA DE UTILIZAÇÃO DE MACRONUTRIENTES EM EUCALIPTO POR MÉTODO NÃO DESTRUTIVO ESTIMADOS POR REDES NEURAIAS ARTIFICIAIS

Tabela 1. Equações para estimar o CUB_{Tronco} para macronutrientes	65
Tabela 2. Precisão das equações obtidas para os CUB's do tronco	65

Tabela 3. Características das redes neurais artificiais (RNA) selecionadas para projetar o CUB _{Tronco} dos macronutrientes	67
Tabela 4. Precisão das redes neurais artificiais (RNA)	68

LISTA DE FIGURAS

CAPÍTULO 1 – MODELAGEM ECOFISIOLÓGICA POR REDES NEURAIS ARTIFICIAIS PARA DIFERENTES ESPAÇAMENTOS EM EUCALIPTO

Figura 1. Dispersão dos erros percentuais em função de <i>DAP</i> e classes de erros para a rede neural artificial construída para estimar os atributos ecofisiológicos aos 101 meses de idade	25
Figura 2. Estimativas dos atributos ecofisiológicos por hectare pela rede neural artificial no tempo	26
Figura 3. Número (<i>NF</i>) e biomassa (<i>BF</i>) de folhas por hectare em função da distancia entre plantas (<i>D</i>) aos 101 meses de idade. ** significativo a 1,0 % de probabilidade	27
Figura 4. Dispersão dos erros percentuais em função de <i>DAP</i> e classes de erros para a rede neural artificial construída para estimar os atributos ecofisiológicos	30
Figura 5. Projeção futura da produção de biomassa de tronco considerando 48 meses a idade atual (<i>I_t</i>) pelas redes neurais artificiais e valores observados x estimados	32

CAPÍTULO 2 – EFICIÊNCIA DE USO DE NUTRIENTES EM EUCALIPTO SOB DIFERENTES ESPAÇAMENTOS AVALIADOS POR MÉTODOS TRADICIONAIS E POR REDES NEURAIS ARTIFICIAIS

Figura 1. Frequências absolutas das classes de <i>DAP</i> e <i>Ht</i> em cada espaçamento na idade de 4 anos. Em que: T1 - 3,0 x 0,5 m; T2 - 3,0 x 1,0 m; T3 - 3,0 x 1,5 m; T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m	44
Figura 2. Frequências absolutas das classes de <i>DAP</i> e <i>Ht</i> em cada espaçamento na idade de 8 anos. Em que: T1 - 3,0 x 0,5 m; T2 - 3,0 x 1,0 m; T3 - 3,0 x 1,5 m; T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m	45
Figura 3. Análise de agrupamento de <i>DAP</i> e <i>Ht</i> em função dos tratamentos. Em que: T1 - 3,0 x 0,5 m; T2 - 3,0 x 1,0 m; T3 - 3,0 x 1,5 m; T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m	46

Figura 4. Comportamento da produção de biomassa ao longo dos anos e distâncias entre plantas em metros (eixo x)	48
Figura 5. Coeficiente de utilização biológico dos macronutrientes para casca, lenho e tronco em função da distância entre plantas (as curvas apresentadas foram obtidas com as equações provenientes da (Tabela 2)	50
Figura 6. Conteúdo de macronutrientes nos componentes casca, lenho e tronco para cada distância entre plantas	51
Figura 7. Distribuição dos resíduos percentuais dos coeficientes de utilização biológico (CUB, kg de biomassa/kg de nutriente) pela rede neural artificial diante do <i>DAP</i> e gráfico de dispersão observado <i>versus</i> estimado	53

CAPÍTULO 3 – EFICIÊNCIA DE UTILIZAÇÃO DE MACRONUTRIENTES EM EUCALIPTO POR MÉTODO NÃO DESTRUTIVO ESTIMADOS POR REDES NEURAIIS ARTIFICIAIS

Figura 1. Distribuição dos resíduos percentuais (eixos y) em função dos CUB's no tronco (eixos x, kg de biomassa/kg de nutriente) pelas regressões	66
Figura 2. Distribuição dos resíduos percentuais (eixos y) em função dos CUB's no tronco (eixos x, kg de biomassa/kg de nutriente) pelas redes	69

INTRODUÇÃO GERAL

As tendências globais ao uso racional dos recursos renováveis, paralelas às restrições ambientais quanto à exploração de madeira nativa e minimização do consumo de combustíveis fósseis, têm motivado pesquisas e plantios comerciais de gêneros como *Eucalyptus* e *Pinus*. O cultivo do eucalipto ampliou-se muito nas últimas décadas. As áreas de florestas plantadas no Brasil somaram em torno de 6,4 milhões de ha em 2009, sendo Minas Gerais o estado com maior área plantada, cerca de 1,3 milhão de ha, representando 29,0 % da área plantada com eucalipto no país (ABRAF, 2010).

O grande potencial da produção silvicultural no Brasil é atribuído às suas condições edafoclimáticas, mas a evolução de produtividade alcançada é decorrente da geração de novos clones, tecnologias e melhorias operacionais desenvolvidas desde 1970. Estudos sobre espaçamentos adequados para a produção madeireira de eucalipto foram desenvolvidos desde o início de sua implantação no Brasil. É notório o conhecimento de que os espaçamentos mais adensados são inicialmente mais produtivos, tendem a estagnar o crescimento e atingir o potencial produtivo do site em idades mais jovens quando se considera a mesma condição edafoclimática e mesmo material genético. Entretanto, a maioria dos trabalhos recomenda espaçamentos em torno de seis a nove metros quadrados como os mais adequados economicamente, principalmente para a produção de carvão e celulose. Esta melhor viabilidade econômica depende fortemente do método de colheita adotado. Com a evolução dos sistemas de colheita mecanizada e a elevação dos preços dos combustíveis fósseis, os espaçamentos mais adensados estão se tornando cada vez mais atrativos, principalmente, para a opção da geração de vapor e energia elétrica com a madeira de eucalipto.

Os atributos que delineiam a qualidade e produtividade (água, luz e nutrientes) em um sítio são naturais e inerentes ao mesmo, mas suas disponibilidades podem distinguir-se entre árvores intra-especificadamente e se acentuar ao longo do tempo com diferenças nas condições ambientais, resultado da competição (Binkley et al., 2010). Embora haja disponibilidade de nutrientes provenientes da adubação, a forte competição por luz e água em plantios fitoenergéticos seleciona árvores com um metabolismo mais eficiente dos recursos do meio, e que se adaptem mais facilmente às condições edafoclimáticas (Camargo et al., 2004). Segundo Sieger et al. (2005), essa adequação ao ambiente pode ocorrer devido aos inúmeros processos fisiológicos, morfológicos e moleculares na planta quando é restringido certo

recurso. Esta adaptação pode se refletir nas taxas de aquisição de recursos para cada árvore e como resultado, surgir indivíduos capazes de dominar as demais.

A eficiência de utilização de nutrientes normalmente é definida como a quantidade de matéria seca produzida por grama do nutriente assimilado ou, simplesmente, o inverso da concentração do nutriente nos tecidos (Chapin, 1980) também é definida como coeficiente de utilização biológico dos nutrientes (CUB), que é a base para a recomendação de fertilizantes e para a classificação nutricional de sítios florestais (Barros et al., 1986). O CUB também pode ser utilizado para auxiliar a seleção de materiais genéticos indicados para diferentes condições edafoclimáticas. Os processos que influenciam o CUB da planta estão relacionados a características morfológicas (sistema radicular eficiente, alta relação raiz-parte aérea e sistema radicular extensivo) e fisiológicas (taxa fotossintética e a capacidade de manter o metabolismo normal com baixo teor de nutrientes nos tecidos) (Novais et al., 2007). De forma geral, os trabalhos que avaliam o CUB são oriundos de delineamento experimentais utilizando-se o método da árvore modelo e/ou modelos de regressão (Santana et al., 2002). Normalmente, o CUB é obtido por meio da análise química de uma amostra representativa de toda extensão do tecido vegetal. Para tanto é necessário o abate da árvore e a determinação da matéria seca.

A prognose da produção obtida por meio de ferramentas estatísticas capazes de refletir o realismo biológico do crescimento vegetal é uma alternativa importante e de grande interesse em decisões operacionais nas empresas florestais. Uma alternativa ao uso de modelos de regressão e interpolação é a utilização da inteligência artificial. As redes neurais artificiais (RNA), também conhecidas como *conexionismo* ou *sistemas de processamento paralelo e distribuído* são modelos computacionais que lembram a estrutura do cérebro humano e integram unidades simples de processamento (neurônios artificiais) que calculam determinadas funções matemáticas (Braga et al., 2007). As RNA criam a possibilidade de um desempenho superior ao dos modelos convencionais que a torna atrativa para solução de uma série de problemas (Haykin, 2001).

O emprego de práticas silviculturais apropriadas associado ao uso de métodos de avaliação nutricional e técnicas estatísticas avançadas pode ser uma alternativa viável no estabelecimento de critérios práticos de caracterização e classificação nutricional, além de permitir obter informações sobre a dinâmica de crescimento dentro de povoamentos florestais, enriquecendo estudos sobre a sustentabilidade e produção de um ecossistema florestal.

REFERÊNCIAS BIBLIOGRÁFICAS

ASSOCIAÇÃO BRASILEIRA DE PRODUTORES DE FLORESTAS PLANTADAS – ABPFP. Anuário estatístico ABRAF: ano base 2009. Brasília, 2010. 140p.

BARROS, N. F.; NOVAIS, R. F.; CARMO, D. N.; NEVES, J. C. L. Classificação nutricional de sítios florestais - Descrição de uma metodologia. **Revista Árvore**, v. 10, n. 2, p. 112-120, 1986.

BINKLEY, D.; STAPE, J. L.; BAUERLE, W. L.; RYAN, M. G. Explaining growth of individual trees: Light interception and efficiency of light use by *Eucalyptus* at four sites in Brazil. **Forest Ecology and Management**, v. 259, p. 1704–1713, 2010.

BRAGA, A. P.; CARVALHO, A. P.; LUDERMIR, T. B. **Redes neurais artificiais: Teoria e aplicações**. 2 ed. Rio de Janeiro: LTC, 2007. 226 p.

CAMARGO, M. L. P.; MORAES, C. B.; MORI, E. S.; GERRINI, I. A.; MELLO, E. J.; ODA, S. Considerações sobre eficiência nutricional em *Eucalyptus*. **Científica**, v. 32, n. 2, p. 191-196, 2004.

CHAPIN, F. S. The mineral nutrition of wild plants. **Annual Review of ecology and systematic**, v.11, p. 233-260, 1980.

HAYKIN, S. **Redes Neurais: Princípios e prática**. 2 ed. Porto Alegre: Bookman, 2001; 900 p.
NOVAIS, R. F.; ALVAREZ, V. H.; BARROS, N; F.; FONTES, R. L. F.; CANTARUTTI, R. B.; NEVES, J. C. L. **Fertilidade do solo**. 1 ed. Viçosa: Sociedade Brasileira de Ciência do Solo, 2007. 1017 p.

SANTANA, R. C.; BARROS, N. F.; NEVES, J. C. L. Eficiência de utilização de nutrientes e sustentabilidade da produção em procedências de *Eucalyptus grandis* e *Eucalyptus saligna* em sítios florestais do estado de São Paulo. **Revista Árvore**, Viçosa-MG, v.26, n.4, p.447-457, 2002.

SIEGER, S. M.; KRISTENSEN, B. K.; ROBSON, C. A.; AMIRSADEGHI, S.; ENG, E. W.; ABDEL-MESIH, A.; MOLLER, I. M.; VANLERBERGHE. The role of alternative oxidase in modulating carbon use efficiency and growth during macronutrient stress in tobacco cells. **Journal of Experimental Botany**, v.56, n. 416, p. 1499–1515, 2005.

CAPÍTULO 1

MODELAGEM ECOFISIOLÓGICA POR REDES NEURAIS ARTIFICIAIS PARA DIFERENTES ESPAÇAMENTOS EM EUCALIPTO

RESUMO – Modelos de crescimento são importantes e amplamente utilizados para prognosticar rendimentos e auxiliar as decisões silviculturais. As redes neurais artificiais (RNA) tratam-se de modelos computacionais que simulam grosseiramente o funcionamento do cérebro humano e sistema nervoso, apresentando uma memória capaz de estabelecer relações entre variáveis independentes para estimar variáveis dependentes. O presente trabalho objetivou avaliar a eficiência da modelagem de biomassa sob diferentes espaçamentos empregando RNA. O experimento foi instalado em blocos ao acaso sendo estudado, em três blocos, o efeito de cinco espaçamentos de plantio: T1 - 3,0 x 0,5 m; T2 - 3,0 x 1,0 m; T3 - 3,0 x 1,5 m; T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m. Realizou-se o inventário florestal contínuo nas idades de 48, 61, 73, 85 e 101 meses. Mensurou-se a área foliar, perímetro foliar e área foliar específica aos 101 meses em uma árvore amostra por unidade experimental. Foram utilizadas RNA para estimar estes atributos ecofisiológicos para todas as árvores e prognosticar a biomassa de tronco. A modelagem por redes neurais artificiais demonstrou-se adequada para estimar a produção de biomassa de tronco em função da idade sob diferentes espaçamentos, utilizando o *DAP* e perímetro foliar como variáveis predictoras.

Palavras-chave: RNA; Biomassa de tronco; Ecofisiologia; Prognose.

ECOPHYSIOLOGY MODELING BY ARTIFICIAL NEURAL NETWORKS FOR DIFFERENT SPACING IN EUCALIPTO

ABSTRACT – Growth models are important and widely used to predict yield and help the forestry decisions. Artificial neural networks (RNA) these are computer models that simulate grossly the human brain and nervous system, with a memory capable of establishing relationships between independent variables to estimate the dependent variables. Therefore, this work aimed to evaluate the efficiency of the modeling of biomass under different spacings using RNA. The research plot was installed in randomized block being studied, in three blocks, the effect of five planting spaces: T1 - 3,0 x 0,5 m; T2 - 3,0 x 1,0 m; T3 - 3,0 x 1,5 m; T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m. Were carried out the continuous forest inventory at ages 48, 61, 73, 85 and 101 months. Measured leaf area, leaf perimeter and leaf areaspecific to 101 months in one tree sample each experimental unit. Were used RNA to estimate these ecophysiological attributes for all the trees and predict the biomass of the trunk. The modeling by artificial neural networks demonstrated to be adequate to estimate the biomass of the trunk in relation to age at different spacings, using the DBH and perimeter leaf as predictor variables.

Key words: RNA; Trunk biomass; Ecophysiology; Prediction.

1. INTRODUÇÃO

A produção de energia limpa a partir da biomassa florestal é uma alternativa sustentável aos combustíveis fósseis (não renováveis), minimizando as emissões de gases nocivos à atmosfera. Povoamentos florestais com espécies de rápido crescimento podem estocar carbono suficiente para o cumprimento da redução das emissões de gases de efeito estufa em 5,0 % abaixo do nível de 1990 por países industrializados (Madeira et al., 2002).

Avanços tecnológicos para aumentar a produtividade são necessários e fornecem subsídios na escolha do material genético mais adaptado, melhor método de plantio, condução e colheita de um povoamento florestal. A acumulação de matéria é uma medida integrada do desempenho fisiológico do vegetal no tempo (Merchant et al., 2010). A sua correlação positiva com a fotossíntese indica que esta é capaz de expressar a competição por espaço, nutrientes, água, energia radiante, temperatura, gás carbônico, eficiência de utilização dos recursos (nutrientes, água, luz) e a interação entre os mesmos (Montaldo et al., 2008; Almeida et al., 2007; Costa et al., 2009).

A quantidade e qualidade de biomassa podem ser afetadas pela competição imposta pelo espaçamento de plantio. Espera-se nos plantios mais adensados maior quantidade inicial de biomassa produzida por área e que a estagnação do crescimento ocorra em idades mais jovens, por causa da intensificação do aproveitamento dos recursos. Ao longo da rotação, as diferenças no crescimento entre diferentes densidades tendem a ser minimizadas (Campos e Leite, 2009).

Modelos de crescimento são importantes e amplamente utilizados para prognosticar rendimentos e auxiliar as decisões silviculturais. No entanto, sua aceitação depende da capacidade de fornecer informações robustas e precisas e da facilidade para utilização e parametrização. Os modelos baseados em atributos do povoamento, empíricos ou processuais, são ferramentas úteis para inferências sobre crescimento futuro de um plantio (Stape et al., 2004).

Os modelos empíricos são, geralmente, curvas ajustadas a dados históricos que predizem a produtividade de uma floresta sem considerar possíveis variações climáticas (Pinjuv et al., 2006). Assim, sua aplicabilidade é limitada às escalas espacial e temporal, não podendo ser aplicado aos locais cuja informação anterior de crescimento é indisponível (Miehle et al., 2009).

Por outro lado, os modelos mecanísticos ou de processo fornecem maior realismo, abrangem tendências do crescimento e pressuposições biológicas (Campos e Leite, 2009). Estes podem produzir estimativas mais precisas acerca da produtividade florestal, uma vez que consideram a influência de fatores ambientais (Almeida et al., 2007). A área foliar específica, área foliar e o perímetro são parâmetros ecofisiológicos que influenciam a capacidade fotossintética e a respiração das folhas, além de úteis para caracterizar adaptações de plantas às condições ambientais. Entre estes, a área foliar específica é comumente empregada em modelos de predição como o 3-PG e CABALA (Nouvellon et al., 2010).

A prognose da produção obtida por meio de ferramentas estatísticas avançadas capazes de refletir o realismo biológico do crescimento vegetal é uma alternativa importante e de grande interesse em decisões operacionais nas empresas florestais. Alternativa à modelagem por relações funcionais como as de Clutter e Buckman, as redes neurais artificiais (RNA) vem se destacando como uma ferramenta que se obtêm adequada precisão. Estas são um sistema paralelo, massivo e integrado por unidades de processamento simples (neurônios artificiais) que calculam determinadas funções matemáticas (Gorgens et al., 2009; Bullinária, 2011). Apesar das redes simular grosseiramente o cérebro humano e sistema nervoso, sua memória associativa e distribuída é capaz de generalizar o conhecimento assimilado por aprendizagem para um conjunto de dados desconhecidos (Binoti, 2010).

As RNA têm apresentado desempenho superior aos modelos de regressão face às suas próprias características de tolerância a falhas e ruídos, adaptabilidade dos pesos das conexões às modificações do ambiente, analogia neurobiológica, resolução de problemas complexos e habilidade de aprendizagem, pois o treinamento consiste no ajuste de parâmetros a partir de exemplos a fim de executar determinada tarefa (Binoti et al., 2010; Binoti, 2010).

Neste contexto, este trabalho objetivou avaliar a eficiência da modelagem da produção de biomassa sob diferentes espaçamentos empregando redes neurais artificiais.

2. MATERIAL E MÉTODOS

O estudo foi conduzido a 17° 50' de latitude sul e 42° 49' de longitude oeste em área Aparam Bioenergia, antiga ACESITA Energética, no município de Itamarandiba-MG. O clima predominante na região é do tipo Cwa, segundo a classificação de Köppen, com verões quentes e chuvosos e invernos amenos e secos, com estação seca bem definida de abril a setembro e déficit hídrico mensal de 30 a 50 mm (INMET, 2010) e com médias anuais de

temperatura e precipitação pluviométrica de 20 °C e 1160 mm, respectivamente (Pulrolnik et al., 2009).

O experimento foi instalado em dezembro de 2002 utilizando-se um híbrido de *Eucalyptus grandis* W. Hill ex Maiden x *Eucalyptus camaldulensis* Dehnh sobre Latossolo Vermelho-Amarelo em relevo plano a 1097 m altitude. Adotou-se delineamento em blocos ao acaso, com três blocos. Os tratamentos foram constituídos pelos seguintes espaçamentos de plantio: T1 - 3,0 x 0,5 m; T2 - 3,0 x 1,0 m; T3 - 3,0 x 1,5 m; T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m, 3 m foi a distância fixa entre linhas de plantio. Foram definidas por tratamento seis linhas de plantio com 28 plantas, totalizando 168 indivíduos, dos quais 48 foram mensurados, por ter sido adotada a bordadura dupla.

Realizou-se o inventário florestal contínuo (IFC) nas idades de 48, 61, 73, 85 e 101 meses mensurando-se o diâmetro a 1,30 m de altura do solo (*DAP*) e altura total (*Ht*) de todas as árvores em cada unidade experimental. Na idade de 101 meses foram abatidas 50 árvores por espaçamento conforme classe diamétrica, amplitude de 5 cm, para realização da cubagem rigorosa até altura comercial (diâmetro de 4,0 cm), totalizando 250 indivíduos. Calculou-se o volume real de lenho (método de Smalian) e estimou-se o volume pelo modelo linearizado de Schumacher e Hall (1933).

Estimou-se para todas as árvores mensuradas nos inventários a biomassa de lenho ($\text{Mg}\cdot\text{ha}^{-1}$) empregando a relação entre volume sem casca (VSC) e a densidade básica (DB). O VSC foi estimado pelo modelo $y = \exp(\beta_0 + \beta_1 \text{LnDAP} + \beta_2 \text{LnHt})$. Retiraram-se discos de 6 cm de espessura a 0%, 25%, 50%, 75% e 100% da altura comercial do tronco aos 101 meses em uma árvore amostra (diâmetro médio quadrático) por unidade experimental, totalizando 15 árvores. De cada disco foram obtidas cunhas opostas, que foram utilizadas para a determinação da DB de acordo o método de imersão em água, descrito por Vital (1984). Os valores de DB foram calculados a partir da média aritmética das densidades das respectivas cunhas.

Mensurou-se a área foliar (*AF*), perímetro foliar (*P*) e área foliar específica (*AFE*), número de folhas e biomassa de folhas aos 101 meses das árvores amostras. A *AF* e o *P* foram mensurados com o medidor de área foliar (CI-203 CID Inc.) em 10 folhas coletadas em cada terço da copa (superior, médio e inferior) das árvores-amostras, somando 30 unidades por copa. A coleta das folhas foi realizada a partir da quinta inserção nos galhos, os quais se encontravam no centro dos terços. Para cálculo da *AFE* as folhas foram secas a 65 °C até peso constante em estufa com circulação forçada de ar. Empregou-se a seguinte fórmula: $AFE = AF \cdot MS^{-1}$, em que: MS = massa seca. Os dados destas variáveis foram submetidos à análise

de correlação segundo Pearson. O número de folhas por hectare foi estimado em função da relação número versus biomassa de folhas amostradas. Para a obtenção da biomassa de folhas nas árvores-amostras, este componente foi pesado em campo e subamostras foram coletadas para obtenção do peso seco. Os dados foram submetidos à análise de variância e quando observado efeito significativo para tratamento realizou-se a análise de regressão.

O treinamento de uma rede neural artificial, também denominado aprendizagem, consiste no ajuste dos parâmetros da rede (pesos e *bias*) através de um algoritmo de aprendizagem. Neste processo os dados de treinamento (conjunto de exemplos) são apresentados a uma arquitetura pré-estabelecida, ou seja, um determinado número de arranjos de neurônios em camadas. E o algoritmo de treinamento extrai características a fim de representar a informação fornecida e desempenhar uma determinada tarefa. As variáveis utilizadas como entrada da RNA para estimação dos atributos ecofisiológicos foram numérica ($DAP_{(cm)}$, $Ht_{(m)}$ e espaçamento entre plantas ($Esp_{(m)}$)) e categórica (ECF: $área\ foliar_{(dm^2)}$ – 1; $perímetro_{(m)}$ – 2 e $área\ foliar\ específica_{(cm^2.g^{-1})}$ – 3) utilizando as árvores-amostras. Com a rede gerada estimou-se para todas as árvores mensuradas nos inventários a AF , P e AFE , cujos resultados médios por parcela foram extrapolados para a unidade de um hectare.

Para projeção da biomassa de lenho (BL) foram gerados 19 modelos de RNA a partir das relações funcionais entre as variáveis numéricas:

$$BL_2 = f(DAP_1, Ht_1, AF_1, P_1, AFE_1, I_1, I_2, Esp)$$

em que: I_1 (idade_(meses)) e Esp (espaçamento entre plantas_(m)); $DAP_{1(cm)}$; $Ht_{1(m)}$; $AF_{1(m^2)}$; $P_{1(Km)}$; e $AFE_{1(cm^2.g^{-1})}$ referem-se aos valores atuais destas variáveis e Bt_2 , I_2 a valores futuros.

Foram utilizadas redes anteroalimentadas (*feedforward*), treinadas por meio do algoritmo da retropropagação do erro (*backpropagation*), ou seja, durante o treinamento da rede foram realizados cálculos partir da camada de entrada da rede para a de saída e o erro propagado para camadas anteriores. Em todos os pré-processamentos foi realizada a normalização e equalização dos dados visando uma maior sensibilidade da rede à variação dos mesmos e captar melhor seu comportamento. Os dados foram divididos em grupos de calibração (80,0 % das amostras) e validação (20,0 %), utilizando o método randômico de amostragem.

Foram treinadas 2000 RNA do tipo *Multilayer Perceptron* (MLP): 100 para estimação dos atributos ecofisiológicos e 1900 para projeção da biomassa do tronco (100 para cada relação funcional). Destas foi selecionada uma com base nos desvios dos valores estimados e observados, sendo, portanto, selecionadas 19 redes para o estudo. A escolha do tipo MLP está

relacionada à atribuição de uma maior complexidade a RNA face ao maior número de entradas, o que aumenta o número de parâmetros ajustados conforme Braga et al. (2007). A definição da arquitetura das redes, ou seja, número de camadas e o número de neurônios por camada foi otimizada pela ferramenta *Intelligent Problem Solver* (IPS) do *software* Statistica 7.0 (Statsoft, 2007).

Os pontos que extrapolaram a tendência geral de cada espaçamento, em atributos ecofisiológicos ou biomassa de tronco não foram eliminados a fim de verificar a capacidade das redes neurais artificiais em lidar com *outliers* ou ruídos. A avaliação da acurácia e da precisão e a comparação do treinamento das redes neurais artificiais foi realizada conforme Tabela 1.

Tabela 1. Sequência implantada na seleção das redes neurais artificiais

	----- Sequência -----	Literaturas
1.	Comparação entre os valores observados e estimados por cada rede pelo teste <i>t</i> a 5 % de probabilidade;	Gorgens et al. (2009).
2.	Comparação das <i>RMSE%</i> e <i>BIAS%</i> entre redes e entre fases de processamento: $RMSE_{\%} = 100 (\sqrt{\sum (y_i - \hat{y}_i)^2 / (n - 1)}) / (\sum \hat{y}_i / n);$ $Bias_{\%} = 100 (\sum (y_i - \hat{y}_i)) / (\sum \hat{y}_i / n);$	Mabvurira e Miina (2002)
3.	Comparação dos <i>erros%</i> entre redes; $erro_{\%} = ((\hat{y} - y) / y) 100$	Binoti (2010)
4.	Comparação entre as estatísticas de probabilidade geradas pelo teste <i>t</i> a 50 % de probabilidade;	-
5.	Comparação entre redes a partir dos gráficos de dispersão e distribuição da frequência percentual de resíduos percentuais	Binoti (2010)

y_i = valores observados. \hat{y}_i = valores preditos. *RMSE* = raiz do quadrado médio do erro. *BIAS* = tendenciosidade. Os passos 1, 2, 3 e 4 podem ser realizados simultaneamente.

Os treinamento e validação das RNA foram realizados com auxílio do *software* Statistica 7.0 (Statsoft, 2007).

3. RESULTADOS E DISCUSSÃO

A estrutura da rede neural artificial para estimação dos atributos ecofisiológicos foi 6-8-1 (número de neurônios nas camadas de entrada, intermediária e saída, respectivamente) com funções de ativação exponencial nas camadas intermediária e de saída. Diante a complexidade da interação ecofisiológica e crescimento vegetal a precisão foi satisfatória. O aprendizado e validação apresentaram em torno de 6,58 % de *RMSE* e 0,48 % de *Bias* com

um comportamento homocedástico concentrando os desvios entre $-12,5$ a $+7,5$ % (Figura 1). Binoti (2010) observou que a maioria dos erros percentuais concentrou-se em $\pm 12,5$ % para projeção do *DAP*, *Ht* e na quantificação e na projeção do volume para povoamentos de eucalipto utilizando RNA.

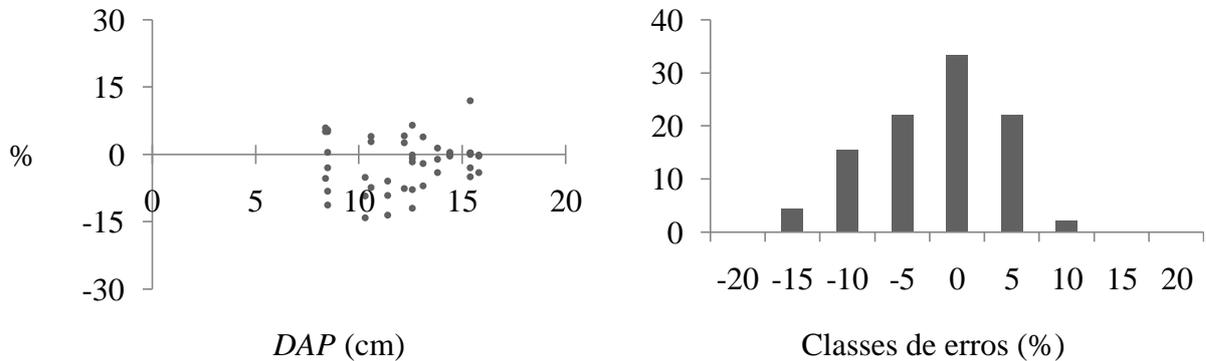


Figura 1. Dispersão dos erros percentuais em função de *DAP* e classes de erros para a rede neural artificial construída para estimar os atributos ecofisiológicos aos 101 meses de idade.

As estimativas dos atributos ecofisiológicos oriundos da generalização da rede neural artificial foram capazes de discriminar a diferença entre espaçamentos em função da idade (Figura 2). A área foliar, perímetro foliar e área foliar específica aumentaram à medida que aumentou a densidade de plantas e o *DAP*, embora tenha expressado pouca variação em função da idade. Esta mesma tendência para *AF*, *P* e *AFE* foi observada por Maire et al. (2011) para *Eucalyptus spp.* Mudanças anatômicas adaptativas nas folhas podem ocorrer quando se tem alteração da intensidade/quantidade luminosa no dossel (Carvalho et al., 2006). Estes resultados estão coerentes com o número e quantidade de folhas estimadas em função da amostragem de biomassa (Figura 3).

A maior área foliar específica nos menores espaçamentos pode ser uma resposta da planta para compensar o maior sombreamento entre as folhas imposta pela competição. Resultados semelhantes foram observados por Alcorn et al. (2008) em estudos com *E. pilularis* e *E. cloeziana*. É importante salientar que tanto o perímetro quanto a área foliar podem ser regulados por variáveis ambientais como temperatura, precipitação (Whitehead e Beadle, 2004) e intensidade luminosa (Forrester et al., 2003). À medida que reduz o espaçamento as árvores tendem a ficar menores devido a maior competição. De forma geral, o crescimento em altura e diâmetro das árvores, por hectare, correlacionou-se negativamente com os atributos ecofisiológicos (Tabela 2).

Tabela 2. Correlações de Pearson entre diâmetro a 1,30 m de altura (*DAP*) e altura total (*Ht*) com área foliar (*AF*), perímetro foliar (*P*) e área foliar específica (*AFE*)

	<i>AF</i>	<i>P</i>	<i>AFE</i>
<i>DAP</i>	-0,819*	-0,851*	-0,789*
<i>Ht</i>	-0,637*	-0,686*	-0,788*

*($p < 0,05$).

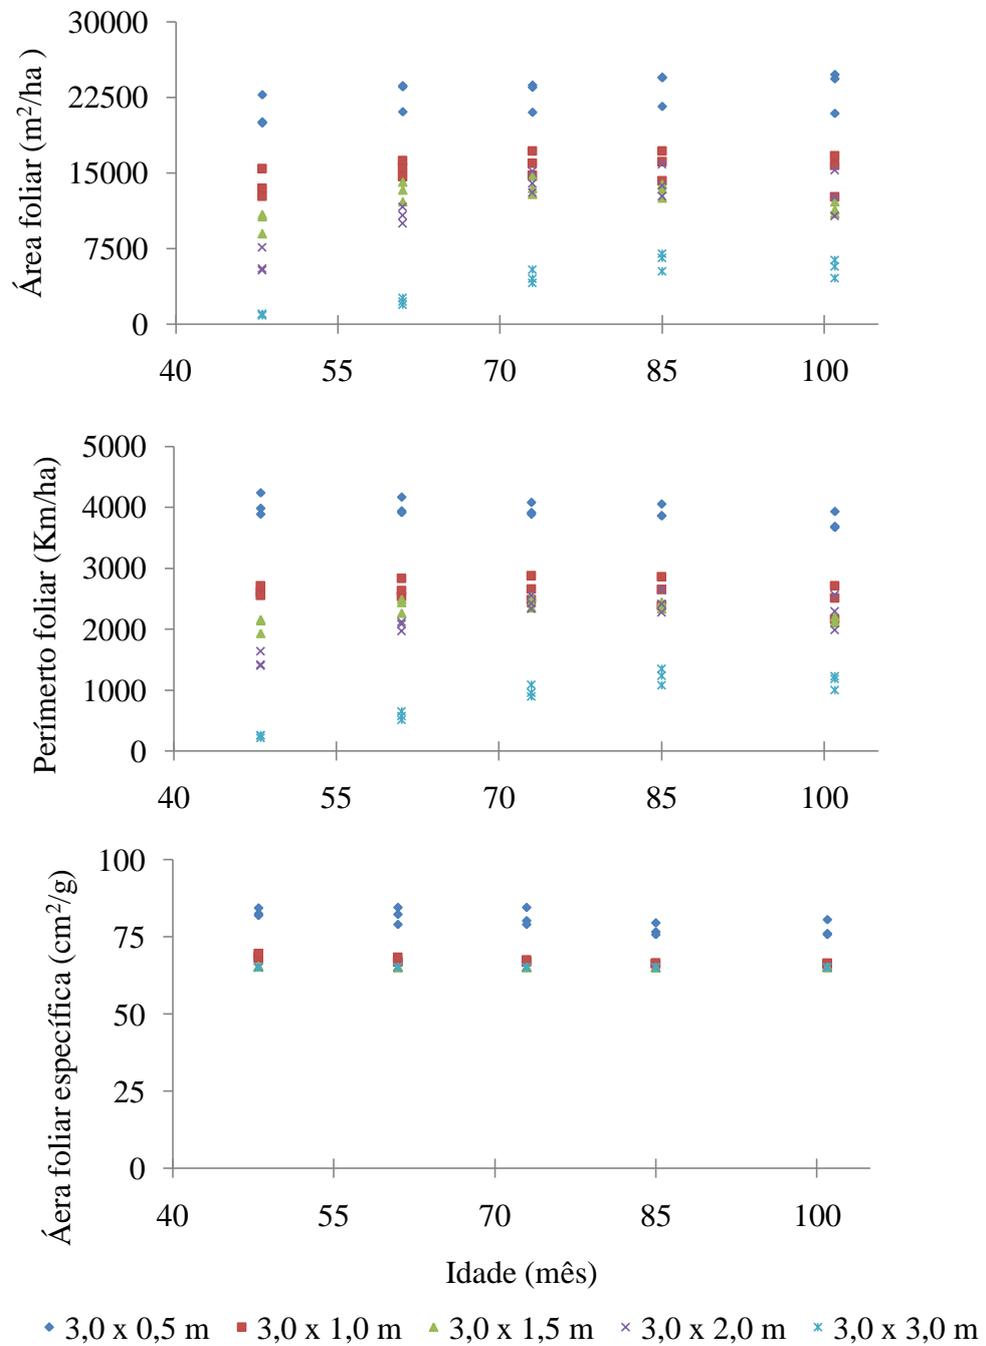


Figura 2. Estimativas dos atributos ecofisiológicos por hectare pela rede neural artificial no tempo.

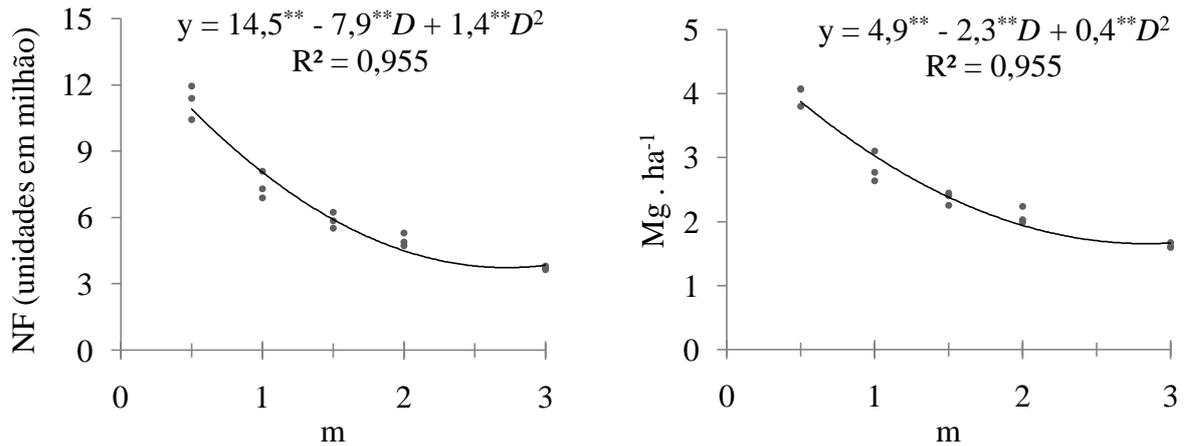


Figura 3. Número (*NF*) e biomassa (*BF*) de folhas por hectare em função da distancia entre plantas (*D*) aos 101 meses de idade. ** significativo a 1,0 % de probabilidade.

A predominância de funções não lineares nas camadas intermediárias foi verificada (Tabela 3). De acordo com Haykin (2001), este comportamento possibilita que a composição das funções nas camadas sucessivas tenha capacidade de resolver os problemas de maior ordem no espaço de entrada. Considerando isoladamente as entradas não comuns entre as redes (RNA 15 a 19), a maior complexidade expressa pelo número de neurônios na camada intermediária foi observada para a área foliar (Tabela 3). As RNA 7, 13, 14, 18 e 19 foram as mais simples como pode ser observado pelo menor número de neurônios na arquitetura das mesmas. Todas as redes para a projeção da biomassa de tronco apresentaram ausência de significância estatística pelo teste *t* a 5,0 % de probabilidade e não tendenciosidade pelos baixos *Bias*, *RMSE*_% e amplitude do erro (Tabela 4), evidenciando a sua capacidade de aprendizado. Ou seja, demonstraram que podem captar o realismo biológico dos dados.

Tabela 3. Características das redes neurais artificiais (RNA) selecionadas para projetar a biomassa de lenho

RNA	n	Arquitetura	Entradas numéricas	Função de ativação	
				Intermediária	Saída
1	60	MLP 8-5-1	$I_1, I_2, Esp, DAP, Ht, AF, P, AFE$	Logística	Exponencial
2	60	MLP 7-12-1	$I_1, I_2, Esp, DAP, AF, P, AFE$	Identidade	Identidade
3	60	MLP 7-4-1	$I_1, I_2, Esp, Ht, AF, P, AFE$	Tangencial	Logística
4	60	MLP 6-4-1	$I_1, I_2, Esp, AF, P, AFE$	Tangencial	Identidade
5	60	MLP 6-10-1	$I_1, I_2, Esp, DAP, AF, P$	Identidade	Exponencial
6	60	MLP 6-8-1	$I_1, I_2, Esp, DAP, AF, AFE$	Logística	Logística
7	60	MLP 6-3-1	$I_1, I_2, Esp, DAP, P, AFE$	Exponencial	Exponencial
8	60	MLP 5-11-1	I_1, I_2, Esp, AF, P	Logística	Exponencial
9	60	MLP 5-6-1	I_1, I_2, Esp, AF, AFE	Tangencial	Tangencial
10	60	MLP 5-7-1	I_1, I_2, Esp, P, AFE	Logística	Tangencial
11	60	MLP 5-9-1	I_1, I_2, Esp, DAP, Ht	Logística	Logística
12	60	MLP 5-4-1	I_1, I_2, Esp, DAP, AF	Logística	Tangencial
13	60	MLP 5-3-1	I_1, I_2, Esp, DAP, P	Logística	Identidade
14	60	MLP 5-3-1	I_1, I_2, Esp, DAP, AFE	Logística	Identidade
15	60	MLP 4-7-1	I_1, I_2, Esp, DAP	Exponencial	Exponencial
16	60	MLP 4-5-1	I_1, I_2, Esp, Ht	Exponencial	Exponencial
17	60	MLP 4-10-1	I_1, I_2, Esp, AF	Logística	Logística
18	60	MLP 4-3-1	I_1, I_2, Esp, P	Logística	Tangencial
19	60	MLP 4-3-1	I_1, I_2, Esp, AFE	Exponencial	Logística

I_1 = Idade atual. I_2 = Idade futura. Esp = Espaçamento. Ht = Altura total. AF = Área foliar. P = Perímetro foliar. AFE = Área foliar específica. n = número de observações.. A densidade básica considerada para estimativa da biomassa de lenho foram, em média por tratamento, de $T1 = 0,52$; $T2 = 0,55$; $T3 = 0,56$; $T4 = 0,56$ e $T5 = 0,55 \text{ g.cm}^{-3}$.

Embora as RNA tenham apresentado um bom treino e uma pior validação, as $RMSE\%$ e $Bias\%$ variaram pouco entre as fases de processamento e as amplitudes dos erros relativos foram baixas, em média de 20,65 % para o treinamento e de 17,89 % para a validação (Tabela 4). Este desempenho não necessariamente foi gerado por uma memorização excessiva dos dados de treinamento. Segundo Palma e Portugal (2009) o sobre-treinamento pode ocorrer quando se tem muitos neurônios na camada intermediária, fato este não observado nestas redes.

Assumindo como referencial para a validação das redes um limite de $RMSE\%$ de 1,2 % acima do $RMSE\%$ observado no treinamento, as RNA 2, 3, 5, 6, 7, 11, 12, 13, 14, 15, 17, e 19 podem ser passíveis de futuras generalizações. Baseado no teste t procedeu-se a seleção das redes por meio das análises gráficas (Figura 4). Em função da ausência de ruídos, simetria da distribuição das classes de erro e da dispersão dos mesmos optou-se pelas redes 7, 13, 14 e 15.

Tabela 4. Precisão das redes neurais artificiais (RNA)

RNA	Fases	<i>RMSE</i> _%	<i>Bias</i> _%	Erros relativos (%)			Teste <i>t</i> <i>p</i>
				Maximo	Media	Mínimo	
1	Treinamento	2,41	-0,11	9,69	0,23	-4,52	0,752413
	Validação	3,97	1,00	4,32	-0,93	-11,09	
2	Treinamento	3,23	0,15	9,31	0,04	-8,64	0,370662
	Validação	3,98	1,34	2,40	-1,24	-10,40	
3	Treinamento	3,57	0,13	10,31	0,05	-11,11	0,567768
	Validação	4,66	0,86	8,84	-0,63	-9,40	
4	Treinamento	4,16	0,00	12,74	0,20	-8,41	0,911233
	Validação	7,12	0,35	9,42	-0,40	-13,88	
5	Treinamento	4,30	0,00	10,61	0,21	-11,16	0,366812
	Validação	4,72	2,60	1,59	-2,50	-11,79	
6	Treinamento	3,38	0,18	9,89	0,02	-8,92	0,293468
	Validação	3,97	1,66	2,89	-1,61	-9,99	
7	Treinamento	3,21	-0,03	10,19	0,17	-9,35	0,799768
	Validação	3,31	0,66	3,83	-0,70	-7,85	
8	Treinamento	5,65	-0,10	13,50	0,45	-8,64	0,441829
	Validação	7,93	3,54	6,98	-3,14	-12,99	
9	Treinamento	5,31	0,01	13,64	0,26	-8,98	0,353278
	Validação	8,28	3,61	7,44	-3,28	-16,63	
10	Treinamento	5,55	0,05	12,84	0,26	-9,56	0,520250
	Validação	10,60	2,65	16,26	-2,16	-16,42	
11	Treinamento	3,65	0,24	11,04	-0,02	-8,90	0,220552
	Validação	4,07	1,97	2,41	-1,89	-9,93	
12	Treinamento	3,04	0,20	10,73	-0,06	-9,22	0,399127
	Validação	3,67	0,93	4,21	-0,91	-9,04	
13	Treinamento	3,25	0,00	9,21	0,12	-7,78	0,535411
	Validação	4,40	1,40	3,84	-1,29	-10,68	
14	Treinamento	3,06	0,00	10,83	0,11	-9,02	0,665018
	Validação	3,67	0,89	5,43	-0,86	-8,41	
15	Treinamento	2,93	-0,04	10,77	0,16	-9,48	0,578868
	Validação	3,49	1,25	3,66	-1,30	-9,39	
16	Treinamento	3,80	0,00	13,58	0,16	-7,62	0,343334
	Validação	6,74	2,78	10,60	-2,44	-15,50	
17	Treinamento	5,89	-0,07	12,68	0,44	-9,73	0,495650
	Validação	7,77	3,09	7,28	-2,70	-11,93	
18	Treinamento	6,33	0,01	13,04	0,39	-12,33	0,413232
	Validação	8,86	3,67	7,89	-3,20	-14,77	
19	Treinamento	6,76	-0,02	12,22	0,48	-12,25	0,488563
	Validação	7,18	3,19	8,71	-2,79	-11,83	

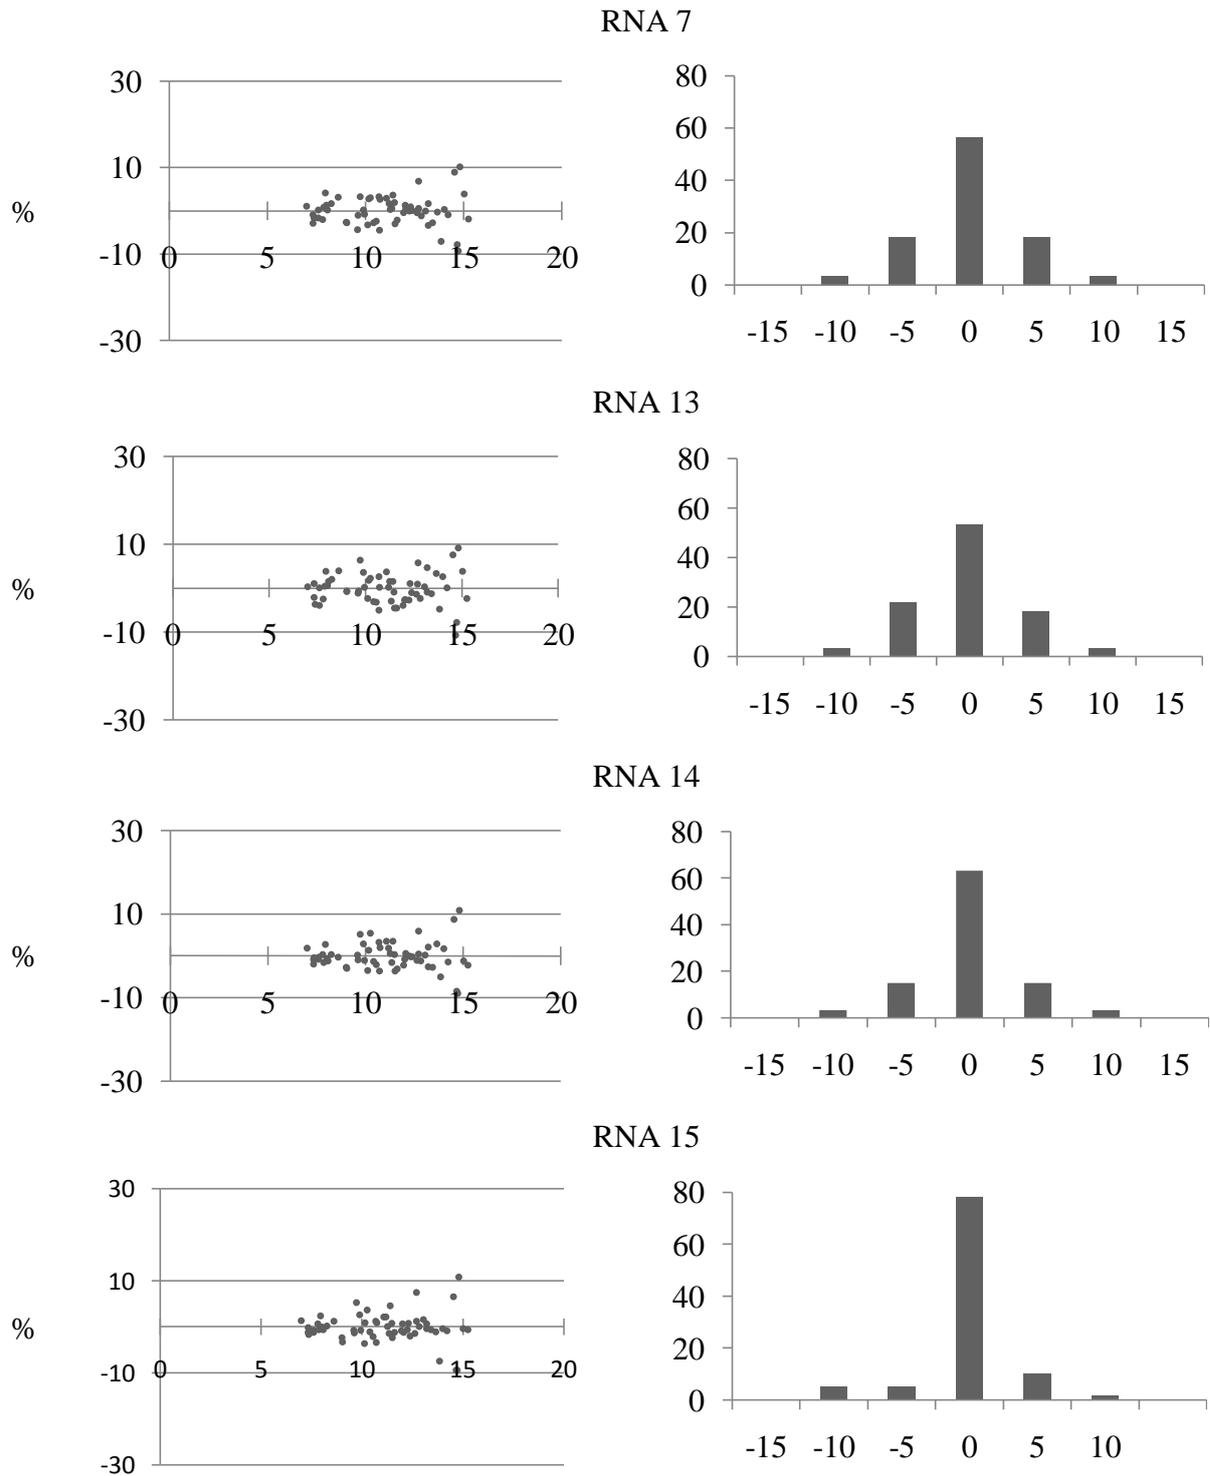


Figura 4. Dispersão dos erros percentuais em função de *DAP* e classes de erros para a rede neural artificial construída para estimar os atributos ecofisiológicos.

A ausência de ruídos observados na Figura 4 comprovou a habilidade das RNA em lidar com os *outliers* durante o processo de ajuste de seus pesos através de um algoritmo de aprendizagem. Após a seleção das redes conduziu-se a projeção futura da produção de

biomassa de lenho considerando 48 meses como I_l (idade atual) (Figura 5) comparando os dados estimados com os observados.

A prognose da biomassa de lenho com as redes 7, 13, 14 e 15 não gerou projeções similares (Figura 5), sendo que as RNA 13 e 14 apresentaram as melhores correlações entre os valores observados e estimados, como também, as melhores projeções ao longo da idade. Entretanto, uma desvantagem observada na rede 14 foi a perda na precisão e subestimação da biomassa de lenho estimada a partir de 73 meses de idade não captando a redução real da taxa de crescimento. A RNA 13 utilizou em sua relação funcional o *DAP* e perímetro foliar.

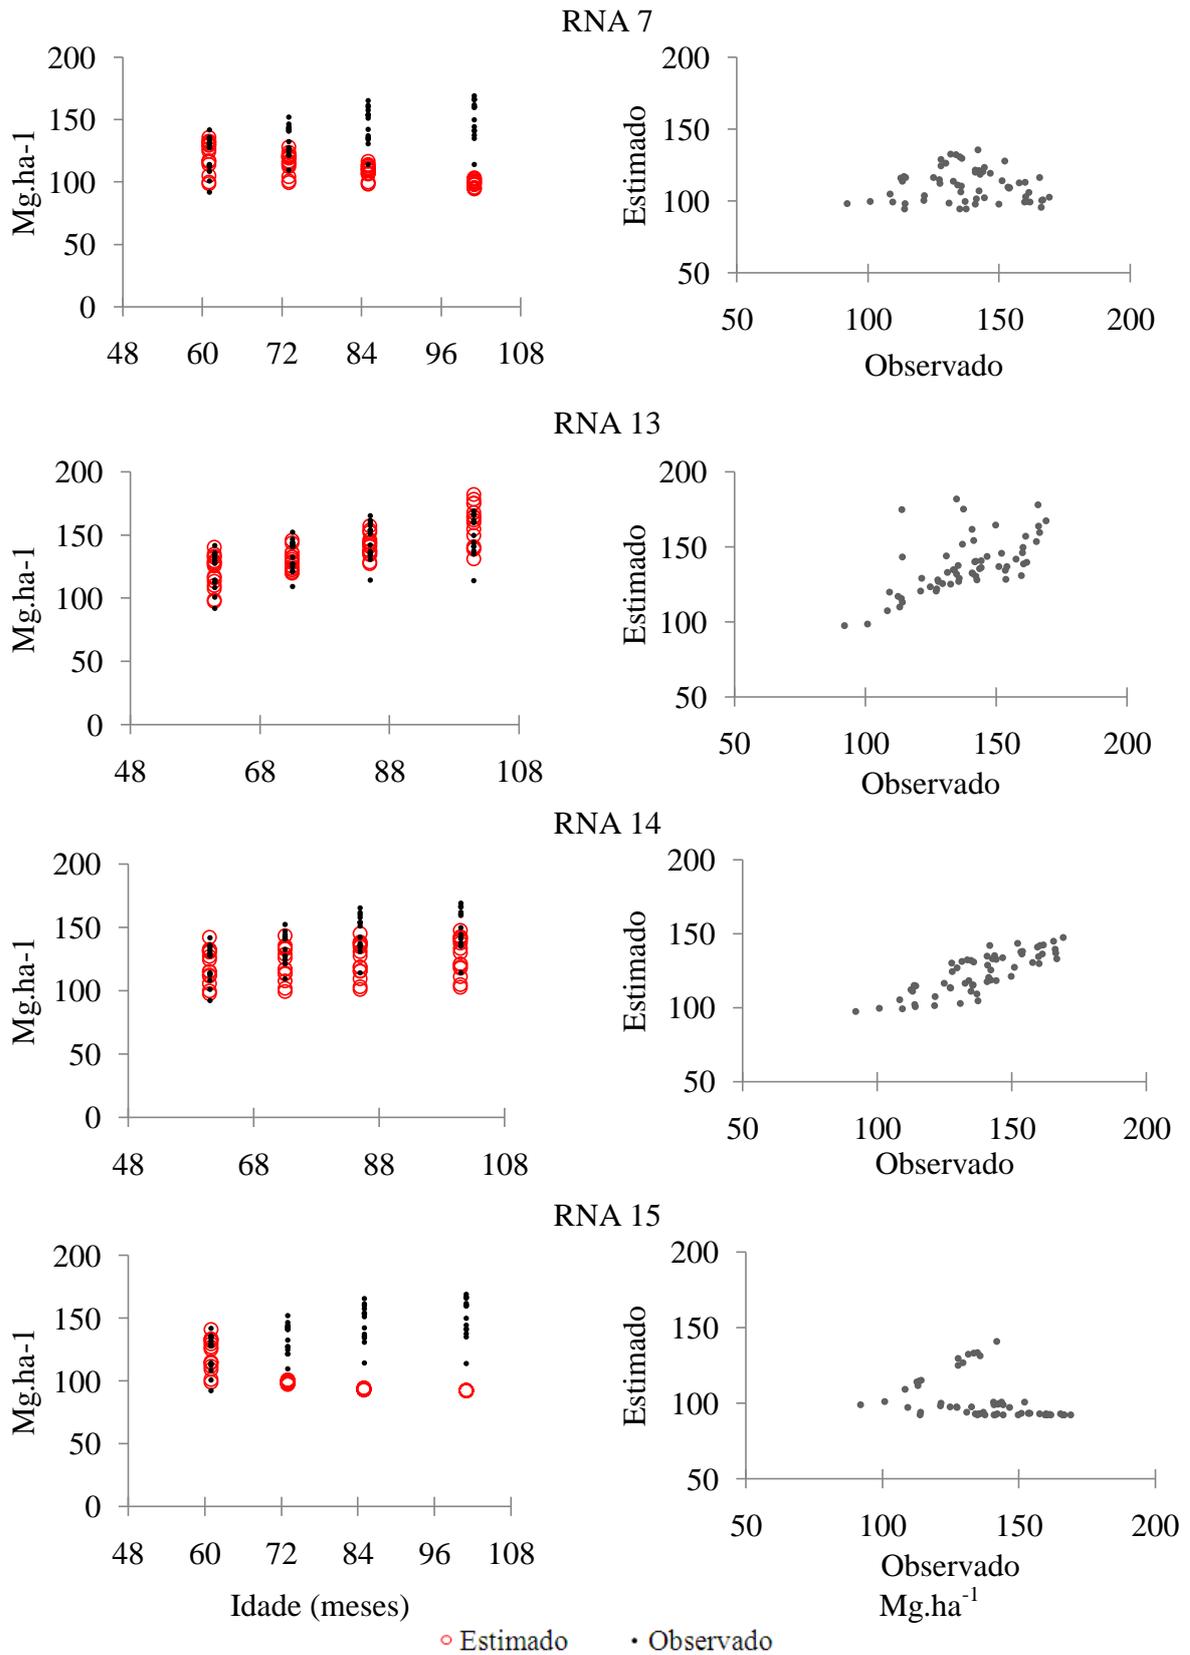


Figura 5. Projeção futura da produção de biomassa de tronco considerando 48 meses a idade atual (I_t) pelas redes neurais artificiais e valores observados x estimados.

4. CONCLUSÃO

A modelagem por redes neurais artificiais demonstrou-se adequada para estimar a produção de biomassa de tronco em função da idade sob diferentes espaçamentos, utilizando o *DAP* e perímetro foliar como variáveis preditoras.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- ALCORN, P. J.; BAUHUS, J.; THOMAS, D. S.; JAMES, R. N.; SMITH, R. G. B.; NICOTRA, A. B. Photosynthetic response to green crown pruning in young plantation-grown *Eucalyptus pilularis* and *E. cloeziana*. **Forest Ecology and Management**, v. 255, p. 3827–3838, 2008.
- ALMEIDA, A. C.; SOARES, J. V.; LANSBERG, J. J.; REZENDE, G. D. Growth and water balance of *Eucalyptus grandis* hybrids plantations in Brazil during a rotation for pulp production. **Forest Ecology and Management**, p. 1-12, 2007.
- BINOTI, M. L. M. S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 2010. 54f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa-MG, 2010.
- BINOTI, D. H. B.; LEITE, H. G.; NOGUEIRA, G. S.; SILVA, M. L. M.; GARCIA, S. L. R.; CRUZ, J. P. Uso da função Weibull de três parâmetros em um modelo de distribuição diamétrica para plantios de eucalipto submetidos a desbaste. **Revista Árvore**, v. 34, n.1, p. 147-156, 2010.
- BULLINÁRIA, J. A. **Introduction to Neural Computation**. Notas de aula. 2011. Disponível em: < <http://www.cs.bham.ac.uk/~jxb/inc.html> >. Acesso em: 8 de nov. 2011.
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração Florestal**. Editora UFV, 3 ed., 261 p., 2009.
- CARVALHO, N. O. S.; PELACANI, C. R.; RODRIGUES, M. O. S.; CREPALDI, I. C. Crescimento inicial de plantas de licuri (*Syagrus coronata* (Mart.) Becc.) em diferentes níveis de luminosidade. **Revista Árvore**, v.30, n.3, p.351-357, 2006.
- COSTA, A. M.; CURI, N.; ARAÚJO, E. F.; MARQUES, J. J.; MENEZES, M. D. Avaliação do risco de anoxia para o cultivo do eucalipto no Rio Grande do Sul utilizando-se levantamento de solos. **Scientia Forestalis**, Piracicaba-SP, v. 37, n. 84, p. 367-375, 2009.
- FORRESTER, D.; BAUHUS, J.; CONNELL, M. Competition in thinned Silver top Ash (*Eucalyptus sieberi* L. Johnson) stands from early coppice growth. **Forest Ecology and Management**, v. 174, p. 459–475, 2003.

- GORGENS, E. B.; LEITE, H. G.; SANTOS, H. N.; GLERIANI, J. M. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, v. 33, n. 6, p. 1141-1147, 2009.
- HAYKIN, S. **Redes neurais: princípios e prática**. 2 ed. Porto Alegre: Bookman, 2001. 900 p.
- INMET – Instituto Nacional de Meteorologia. Disponível em: <<http://www.inmet.gov.br>>. Acesso em 16 de out. 2010.
- MABVURIRA, D.; MIINA, J. Individual-tree growth and mortality models for *Eucalyptus grandis*(Hill) Maiden plantations in Zimbabwe. **Forest Ecology and Management**, v. 161, p. 231-245, 2002.
- MADEIRA, M. V.; FABIÃO, A.; PEREIRA, J. S.; ARAÚJO, M. C.; RIBEIRO, C. Changes in carbon stocks in *Eucalyptus globules* Labill. plantations induced by different water and nutrient availability. **Forest Ecology and Management**, v. 171, p. 75–85, 2002.
- MAIRE, G.; MARSDEN, C.; VERHOEF, W.; PONZONI, F. J.; SEEN, D.; BÉGUÉ, A.; STAPE, J. L.; NOUVELLON, Y. Leaf area index estimation with MODIS reflectance time series and model inversion during full rotations of *Eucalyptus* plantations. **Remote Sensing of Environment**, v. 115, p. 586–599, 2011.
- MERCHANT, A. PEUKE, A. D.; KEITEL, C.; MACFARLANE, C.; WARREN, C. R.; ADAMS, M. A. Phloem sap and leaf $\delta^{13}\text{C}$, carbohydrates, and amino acid concentrations in *Eucalyptus globulus* change systematically according to flooding and water deficit treatment. **Journal of Experimental Botany**, v. 61, n. 6, p. 1785–1793, 2010.
- MIEHLE, P.; BATTAGLIA, M.; SANDS, P. J.; FORRESTER, D. I.; FEIKEMA, P. M.; LIVESLEY, S. J.; MORRIS, J. D.; ARNDT, S. K. A comparison of four process-based models and a statistical regression model to predict growth of *Eucalyptus globules* plantations. **Ecological Modelling**, v. 220, p. 734–746, 2009.
- MONTALDO, N.; ALBERTSON, J. D.; MANCINI, M. Vegetation dynamics and soil water balance in a water-limited Mediterranean ecosystem on Sardinia, Italy. **Hydrology and Earth System Sciences**, v. 12, p. 1257–1271, 2008.
- NOUVELLON, Y.; LACLAU, J. -P.; EPRON, D.; KINANA, A.; MABIALA, A.; ROUPSARD, O.; BONNEFOND, J. M.; MAIRE, G.; MARSDEN, C.; BONTEMPS, J. D.; SAINT-ANDRÉ, L. Within-stand and seasonal variations of specific leaf area in a clonal *Eucalyptus* plantation in the Republic of Congo. **Forest Ecology and Management**, v. 259, p. 1796–1807, 2010.
- PALMA, A. A.; PORTUGAL, M. S. Expectativas de inflação no Brasil: Uma aplicação de redes neurais artificiais a dados em painel. **Revista de Economia Contemporânea**, v. 13, n. 3, p. 391-437, 2009.
- PINJUV, G.; MASON, E. G.; WATT, M. Quantitative validation and comparison of a range of forest growth model types. **Forest Ecology and Management**, v. 236, p. 37–46, 2006.

PULROLNIK, K.; BARROS, N. F.; SILVA, I. R.; NOVAIS, R. F.; BRANDANI, C. B. Estoques de carbono e nitrogênio em frações lábeis e estáveis da matéria orgânica de solos sob eucalipto, pastagem e cerrado no Vale do Jequitinhonha-MG. **Revista Brasileira de Ciência do Solo**, v. 33, p. 1125-1136, 2009.

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

STAPE, J. L.; RYAN, M. G.; BINKLEY, D. Testing the utility of the 3-PG model for growth of *Eucalyptus grandis* x *E. urophylla* with natural and manipulated supplies of water and nutrients. **Forest Ecology and Management**, v. 193, p. 219–234, 2004.

STATSOFT, INC. Statistica (data analysis software system), version 7. Disponível em: <<http://www.statsoft.com>>, 2007.

VITAL, B. R. **Métodos de determinação da densidade da madeira**. Viçosa, MG: Sociedade de Investigações Florestais, 1984. 21 p.

WHITEHEAD, D.; BEADLE, C. L. Physiological regulation of productivity and water use in *Eucalyptus*: a review. **Forest Ecology and Management**, v. 193, p. 113–140, 2004.

CAPÍTULO 2

EFICIÊNCIA DE USO DE NUTRIENTES EM EUCALIPTO SOB DIFERENTES ESPAÇAMENTOS AVALIADOS POR MÉTODOS TRADICIONAIS E POR REDES NEURAS ARTIFICIAIS

RESUMO – O coeficiente de utilização biológico (CUB) dos nutrientes é definido como a quantidade de matéria seca produzida por grama do nutriente ou, simplesmente, o inverso da concentração do nutriente nos tecidos. Os objetivos do presente trabalho foram avaliar os CUB's dos nutrientes pelo eucalipto em função do espaçamento e a possibilidade de aplicação de redes neurais artificiais na estimação da eficiência. O experimento foi instalado em blocos ao acaso sendo estudado, em três blocos, o efeito de cinco espaçamentos de plantio: T1 - 3,0 x 0,5 m; T2 - 3,0 x 1,0 m; T3 - 3,0 x 1,5 m; T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m.. Foram abatidas 15 árvores-amostras para cubagem rigorosa, quantificação de biomassa e análise química de N, P, K, Ca, Mg e S. Realizou-se ANOVA, regressão e aplicação de redes neurais artificiais. Não houve grande variação da eficiência de uso dos nutrientes entre os espaçamentos, principalmente para o tronco. A rede neural artificial foi eficiente em estimar a eficiência de uso dos nutrientes.

Palavras-chave: CUB; RNA; Densidade de plantio; Florestas energéticas.

**EFFICIENCY USE NUTRIENTS IN EUCALIPTO UNDER DIFFERENTS SPACINGS
EVALUATED BY TRADITIONAL METHODS AND BY ARTIFICIAL NEURAL
NETWORKS**

ABSTRACT – The coefficient of biological use (CUB) of nutrients is defined as the amount of dry matter produced per gram of nutrient or, simply, the inverse of the concentration of nutrients in the tissues. This work aimed to evaluate the CUB's nutrients by eucalipto according to the spacing and the possibility of application of artificial neural networks (RNA) in estimating efficiencies. The research plot was installed in randomized block being studied, in three blocks, the effect of five planting spaces: T1 - 3,0 x 0,5 m; T2 - 3,0 x 1,0 m; T3 - 3,0 x 1,5 m; T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m. Were felled 15 samples-trees to cubage, quantification of biomass and chemical analysis of N,P, K, Ca, Mg and S. Statistical analysis of the data consisted of ANOVA, regression and application of RNA. There wasn't wide variation in efficiency use nutrient among spacings, especially for the trunk. The artificial neural network was effective in estimating the efficiency of nutrient use.

Key words: CUB; RNA; Planting density; Energy forests.

1. INTRODUÇÃO

A qualidade e a produtividade dos povoamentos florestais são fatores determinantes para a conquista de bons mercados e para se obter um fluxo contínuo de matéria-prima. As maiores produtividades no Brasil são atribuídas aos avanços nas pesquisas e desenvolvimento de novas tecnologias. Na década de 70, as plantações de *Eucalyptus* apresentavam incremento em torno de $15 \text{ m}^3 \cdot \text{ha}^{-1} \cdot \text{ano}^{-1}$, após 35 anos, esse valor triplicou por meio de avanços silviculturais no preparo do solo, melhoramento genético, metodologia de propagação, adubação e controle de pragas (Stape et al., 2010)

O cultivo de espécies florestais está sujeito a uma série de fatores ecológicos que podem afetar de forma direta ou não a produção e o crescimento das árvores, podendo ser classificados como abióticos e bióticos (Bredolan et. al., 2000). Portanto, as propriedades que determinam a qualidade ou produtividade de um local são naturais e inerentes ao mesmo, mas podem ser influenciados pelas práticas de manejo adotadas como a densidade do plantio (Skovsgaard e Vanclay, 2008).

No caso de florestas energéticas que utiliza espaçamentos reduzidos, conciliar a limitação de espaço a ser explorado por uma árvore, o incremento na produtividade, rotações mais curtas e uso sustentável dos recursos é um grande desafio para a silvicultura. A densidade de plantio exerce influência sobre o crescimento de plantas. Plantios em espaçamentos mais adensados são importantes em termos energéticos porque tendem a estagnar o crescimento e atingir o potencial produtivo em idades mais jovens quando se considera a mesma condição edafoclimática e mesmo material genético. Em contrapartida, devido a rotações mais curtas, o manejo silvicultural é mais intensivo e este poderá reduzir os efeitos benéficos do cultivo mínimo se adequações nas práticas de manejo de solo, água, nutrição florestal e colheita não forem adotadas.

A disponibilidade de recursos que influenciam a produtividade (água, luz, nutrientes, energia radiante, temperatura e gás carbônico) pode distinguir-se entre árvores intra-especificadamente e se acentuar ao longo do tempo com diferenças nas condições ambientais, resultado da competição (Binkley et al., 2010). A maior limitação ao crescimento de florestas no Brasil é imposta pela disponibilidade de água (Santana et al., 1999; Stape et al., 2010) e esta pode ser substancialmente potencializada, considerando a produção individual ao se aumentar muito a densidade de plantio. A forte competição por luz e água em plantios

fitoenergéticos pode influenciar a eficiência de uso destes recursos e gerar indivíduos de menor porte, mesmo que haja disponibilidade de nutrientes provenientes de fertilizações.

Estudos que avaliam a absorção de nutrientes pelas plantas e sua relação com a produção de biomassa, ou seja, sua eficiência de uso, são úteis para adotar procedimentos que minimizem a exportação de nutrientes uma vez que o emprego de sucessivas rotações com elevadas produtividades impõem elevada demanda de nutrientes sobre o sítio. A eficiência de utilização de nutriente normalmente definida como quantidade de matéria seca produzida por grama do nutriente ou, simplesmente, o inverso da concentração do nutriente nos tecidos (Chapin, 1980) também definida como coeficiente de utilização biológico dos nutrientes (CUB) pode ser usada para auxiliar a seleção de materiais genéticos indicados para diferentes condições edafoclimáticas e para a recomendação de fertilizantes (Barros et al., 1986; Barros et al., 1995). Os processos que influenciam o CUB da planta estão relacionados com características morfológicas (sistema radicular eficiente, alta relação raiz-parte aérea e sistema radicular extensivo) e fisiológicas (taxa fotossintética e a capacidade de manter o metabolismo normal com baixo teor de nutrientes nos tecidos) (Novais et al., 2007). De forma geral os trabalhos que avaliam o CUB são oriundos de delineamento experimentais utilizando-se o método da árvore modelo e, ou modelos de regressão (Santana et al., 2002).

Uma alternativa à modelagem utilizando-se regressão e interpolação é a utilização da inteligência artificial. As redes neurais artificiais (RNA) são modelos computacionais que simulam o funcionamento do sistema nervoso humano, especificadamente o cérebro, estabelecendo relações entre variáveis independentes para estimar variáveis dependentes (Coelho et al., 2007). Trata-se de um sistema massivo e paralelo integrado por unidades simples de processamento denominados neurônios artificiais, que são interligados entre si de uma maneira específica para executar uma determinada função matemática (Binoti, 2010). As RNA são capazes de generalizar o conhecimento assimilado por um conjunto de exemplos apresentados para um conjunto de dados desconhecidos (Gorgens et al., 2009), assim possuem as seguintes características: analogia neurobiológica, mapeamento de entrada e saída, tolerância a falhas e ruídos, adaptabilidade dos pesos das conexões às modificações do ambiente e generalização do conhecimento assimilado por aprendizagem para um conjunto de dados desconhecidos (Binoti, 2010).

O emprego de práticas silviculturais apropriadas associado ao uso de métodos de avaliação nutricional e técnicas estatísticas pode ser uma alternativa viável na busca de informações sobre a dinâmica de crescimento de povoamentos florestais, podendo ser usadas em estudos sobre a sustentabilidade e produção de um ecossistema florestal. Portanto, o

presente trabalho objetivou avaliar a eficiência de uso dos nutrientes pelo eucalipto em função do espaçamento e a possibilidade de aplicação de redes neurais artificiais na estimação da eficiência.

2. MATERIAL E MÉTODOS

O estudo foi conduzido a 17° 50' de latitude sul e 42° 49' de longitude oeste em área da Aperam Bioenergia, antiga ACESITA Energética, no município de Itamarandiba-MG. O clima predominante na região é do tipo Cwa, segundo a classificação de Köppen, com verões quentes e chuvosos e invernos amenos e secos com estação seca bem definida de abril a setembro e déficit hídrico mensal de 30 a 50 mm (INMET, 2010) e com médias anuais de temperatura e precipitação pluviométrica de 20 °C e 1160 mm, respectivamente (Pulrolnik et al., 2009).

O experimento foi instalado em dezembro de 2002 utilizando-se um híbrido de *Eucalyptus grandis* W. Hill ex Maiden x *Eucalyptus camaldulensis* Dehnh em Latossolo Vermelho-Amarelo com relevo plano a 1097 m altitude. Adotou-se delineamento em blocos ao acaso com três blocos, sendo estudado o efeito de cinco tratamentos constituídos pelos seguintes espaçamentos de plantio: T1 - 3,0 x 0,5 m; T2 - 3,0 x 1,0 m; T3 - 3,0 x 1,5 m; T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m; 3 m a distância fixa entre linhas de plantio. Cada parcela experimental foi constituída de seis linhas de plantio e em cada linha foram plantadas 28 mudas, perfazendo um total de 168 indivíduos por tratamento. Mensurou-se 48 árvores em cada parcela por ter sido adotada a bordadura dupla entre parcelas.

Aos oito anos de idade mensurou-se o diâmetro a 1,30 m de altura do solo (*DAP*) e altura total (*Ht*) de todas as árvores. Foram abatidas 50 árvores por espaçamento conforme classe diamétrica (amplitude de 5 cm) para realização da cubagem rigorosa até altura comercial (diâmetro de 4,0 cm), totalizando 250 indivíduos. Calculou-se o volume real de lenho (método de Smalian) e estimou-se o volume pelo modelo linearizado de Schumacher e Hall (1933).

Os dados de *DAP* e *Ht* foram submetidos à análise estatística descritiva com histogramas de frequências e *Cluster* utilizando-se o Método Aglomerativo Hierárquico. Para permitir a união entre os grupos foi utilizado o Método Ward de ligação ou Método da Mínima Variância, o qual permite calcular a média de todas as variáveis em cada grupo e a distância Euclidiana.

Estimou-se para todas as árvores mensuradas a biomassa de lenho ($\text{Mg}\cdot\text{ha}^{-1}$) empregando a relação entre volume sem casca (VSC) e a densidade básica (DB). O VSC foi estimado pelo modelo $y = \exp(\beta_0 + \beta_1 \text{LnDAP} + \beta_2 \text{LnHt})$. A biomassa da casca foi estimada em função da sua proporção no tronco obtida nas árvores amostras. Retiraram-se discos de 6 cm de espessura a 0%, 25%, 50%, 75% e 100% da altura comercial do tronco aos 101 meses em uma árvore amostra (diâmetro médio quadrático) por unidade experimental, totalizando 15 árvores. De cada disco foram obtidas cunhas opostas, que foram utilizadas para a determinação da DB de acordo o método de imersão em água, descrito por Vital (1984). Os valores de DB foram calculados a partir da média aritmética das densidades das respectivas cunhas.

Após abater as árvores amostras, os seus componentes foram pesados no campo e subamostras foram coletadas da casca e do lenho e secas a 65 °C até peso constante em estufa com circulação forçada de ar. O material vegetal foi moído e submetido à digestão nítrico-perclórica para realizar a análise química de macronutrientes. Os teores de P foram determinados por colorimetria, de K por fotometria de emissão de chama, de S por turbidimetria, Ca e Mg por espectrofotometria de absorção atômica. O N total foi determinado pelo método Kjeldhal após digestão sulfúrica.

As árvores-amostras foram utilizadas para estimar a biomassa e o conteúdo de macronutrientes na casca e lenho por regressão. Esta decisão baseou-se na premissa que existe pouca variação dos teores de nutrientes entre as classes diamétricas, conforme observado por Neves (2000). As equações obtidas foram aplicadas em todas as árvores mensuradas para obter a estimativa de nutrientes. Em seguida calculou-se o CUB da casca, do lenho e do tronco por tratamento em hectare (kg matéria seca por kg de nutrientes; Barros et al. (1986). Os dados foram submetidos à análise de variância e regressão linear quadrática ($y = \beta_0 + \beta_1 D + \beta_2 D^2$) pelo método dos mínimos quadrados ordinários (MQO) utilizando o procedimento iterativo Levenberg-Marquardt, em que “D” foi a distância entre plantas (m) e o CUB a variável dependente por macronutriente. Realizou-se análise gráfica, teste de significância e coeficiente de determinação. Além disso, para a biomassa foi conduzida uma análise descritiva com os dados do inventário atual e anteriores (4, 5, 6 e 7 anos).

O treinamento de uma rede neural artificial, também denominado aprendizagem, consiste no ajuste dos parâmetros da rede (pesos e *bias*) através de um algoritmo de aprendizagem. Neste processo os dados de treinamento (conjunto de exemplos) são

apresentados a uma arquitetura pré-estabelecida, ou seja, um determinado número de arranjos de neurônios em camadas. E o algoritmo de treinamento extrai características a fim de representar a informação fornecida e desempenhar uma determinada tarefa. As variáveis utilizadas como entrada da RNA para estimação dos CUB's tronco por macronutriente foram de caráter numérico ($DAP_{(cm)}$, $Ht_{(m)}$ e espaçamento entre plantas ($Esp_{(m)}$)) e categórico (NID : N – 1; P – 2; K – 3; Ca – 4; Mg – 5 e S – 6).

Utilizaram-se redes anteroalimentadas (*feedforward*), treinadas por meio do algoritmo da retropropagação do erro (*backpropagation*), ou seja, durante o treinamento da rede foram realizados cálculos partir da camada de entrada da rede para a de saída e o erro propagado para camadas anteriores. Em todos os pré-processamentos foi realizada a normalização e equalização dos dados visando uma maior sensibilidade da rede à variação dos mesmos para captar melhor seu comportamento. Os dados foram divididos em grupos de calibração (60,0 % das amostras), validação (20,0 %) e teste (20,0 %) utilizando o método randômico de amostragem.

Foram treinadas 100 RNA para estimar o CUB_{Tronco} . Destas foram selecionadas duas com base nos desvios dos valores estimados e observados. A definição da arquitetura das redes, ou seja, número de camadas e o número de neurônios por camada foi otimizada pela ferramenta *Intelligent Problem Solver* (IPS) do *software* Statistica 7.0 (STATSOFT, INC, 2007). A definição da arquitetura das redes, ou seja, número de camadas e o número de neurônios por camada foi otimizada pela ferramenta *Intelligent Problem Solver* (IPS) do *software* Statistica 7.0 (Statsoft, 2007).

A avaliação da acurácia e precisão do treinamento das RNA foram realizadas por meio do *erro%*, teste de *RMSE%*, teste de *Bias%* e análise gráfica. As estimativas foram comparadas por meio do teste *t* pareado a 5,0 % de probabilidade com os valores observados conforme Gorgens et al. (2009). O erro foi assim definido $erro_{\%} = ((\hat{y} - y)/y)100$, enquanto que a raiz do quadrado médio do erro (*RMSE%*) e a tendenciosidade (*Bias%*) foram determinadas segundo Mabvurira e Miina (2002): $RMSE_{\%} = 100 (\sqrt{\sum(y_i - \hat{y}_i)^2 / (n - 1)}) / (\sum \hat{y}_i / n)$ e $Bias_{\%} = 100 (\sum(y_i - \hat{y}_i)) / (\sum \hat{y}_i / n)$, em que y_i e \hat{y}_i são os valores observados e preditos, respectivamente.

A escolha das melhores redes baseou-se nas mesmas premissas utilizadas no capítulo 1. Todas as análises estatísticas foram realizadas com auxílio do *software* Statistica7.0 (Statsoft, 2007).

3. RESULTADOS E DISCUSSÃO

A densidade de plantas influenciou o crescimento em *DAP* e em altura (Figura 1 e 2), as árvores foram maiores nos plantios mais espaçados, principalmente comparando-se T1 com T5 corroborando com os resultados obtidos em vários trabalhos (Harrison et al., 2000; Leles et al., 2001; Woodruff et al., 2002). No maior espaçamento ocorreu concentração de árvores nas classes centrais. Este fato é importante quando se prevê corte mecanizado, principalmente utilizando o harvester, pois o rendimento operacional é maior quando se tem árvores mais homogêneas de maior diâmetro (Lopes et al., 2007).

A competição aumentou a frequência de árvores menores (Figura 2) corroborando com os resultados observados por Martins et al. (2011). O efeito da competição também foi comprovado pela distribuição assimétrica à esquerda tanto do diâmetro quanto da altura total no T1 (3,0 x 0,5 m), visto que, a partir deste as árvores maiores apresentaram taxas de crescimento superiores às menores, suprimidas, provocando uma assimetria à direita que é comum nos plantios equiâneos (Binoti et al., 2010).

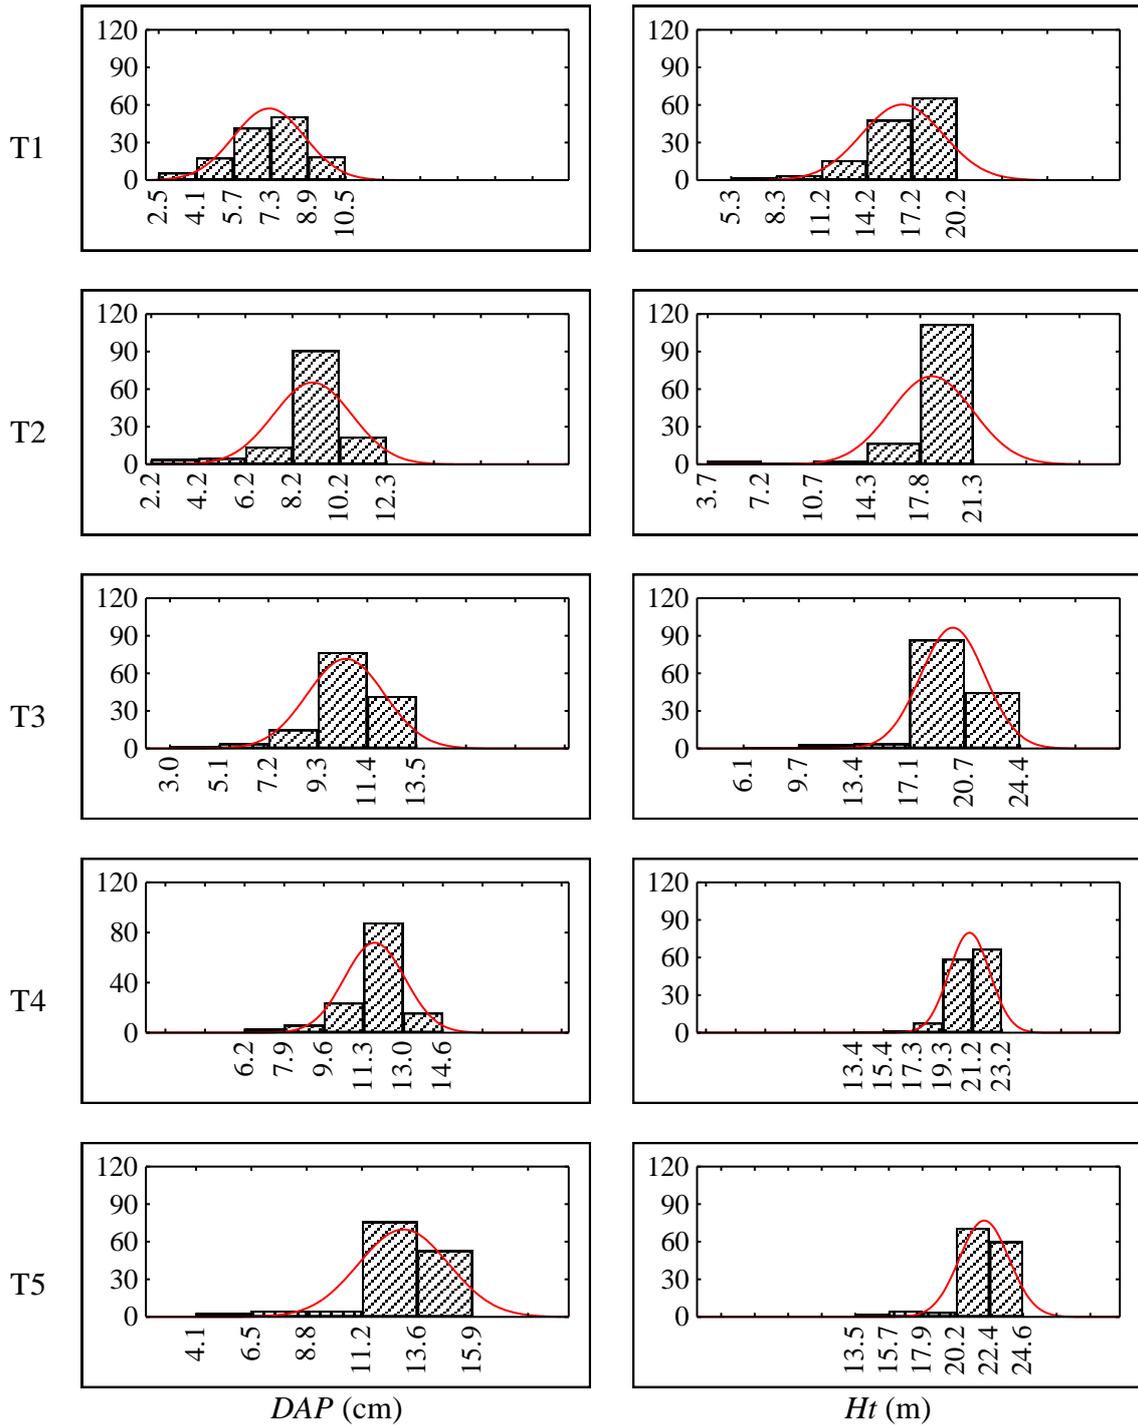


Figura 1. Frequências absolutas das classes de *DAP* e *Ht* em cada espaçamento na idade de 4 anos. Em que: T1 - 3,0 x 0,5 m; T2 - 3,0 x 1,0 m; T3 - 3,0 x 1,5 m; T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m.

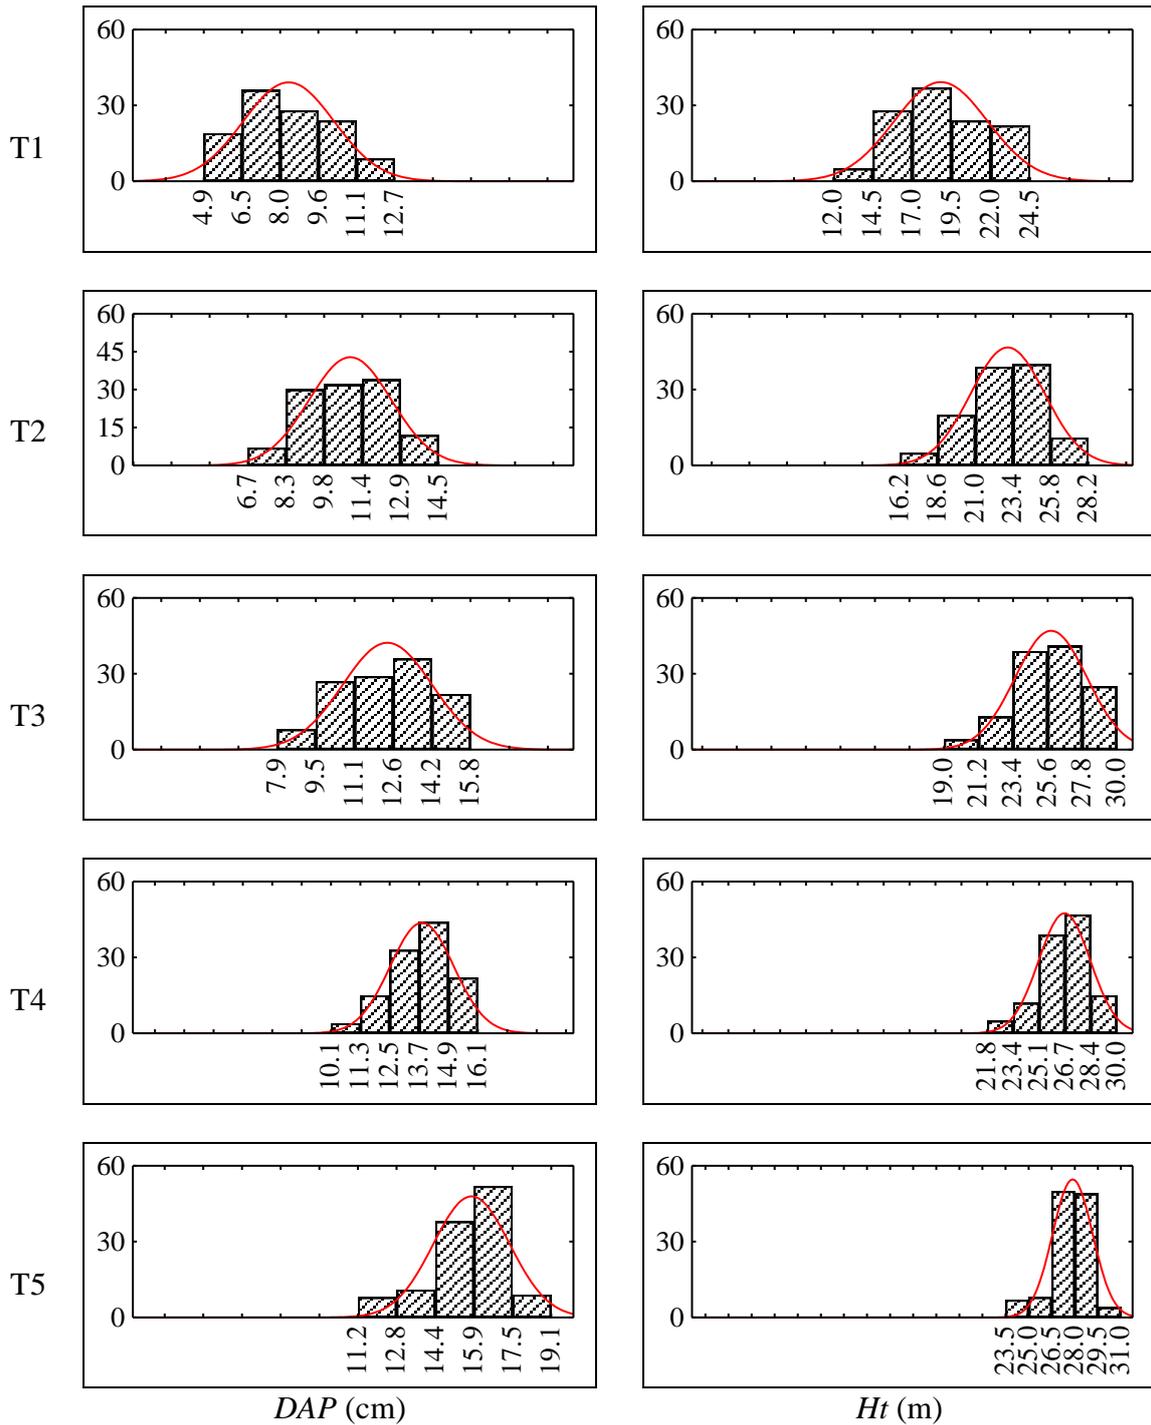


Figura 2. Frequências absolutas das classes de *DAP* e *Ht* em cada espaçamento na idade de 8 anos. Em que: T1 - 3,0 x 0,5 m; T2 - 3,0 x 1,0 m; T3 - 3,0 x 1,5 m; T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m.

A análise de *Cluster* assumindo uma distancia euclidiana de 25 (Figura 3) resultou em três e dois agrupamentos para *DAP* e *Ht*, respectivamente aos 4 e 8 anos de idade. Este fato demonstra que se não houver a colheita das árvores no momento da estagnação da taxa de crescimento, com o passar do tempo todos os espaçamentos tenderão para uma mesma produção final. O tratamento T1 constituiu um grupo único aos 4 e 8 anos e foi o que mais se diferenciou do T5 quanto ao *DAP*. Quando se opta por diferentes espaçamentos o silvicultor deverá atentar-se para a adequada idade de corte ou para aplicação de técnicas como o desbaste.

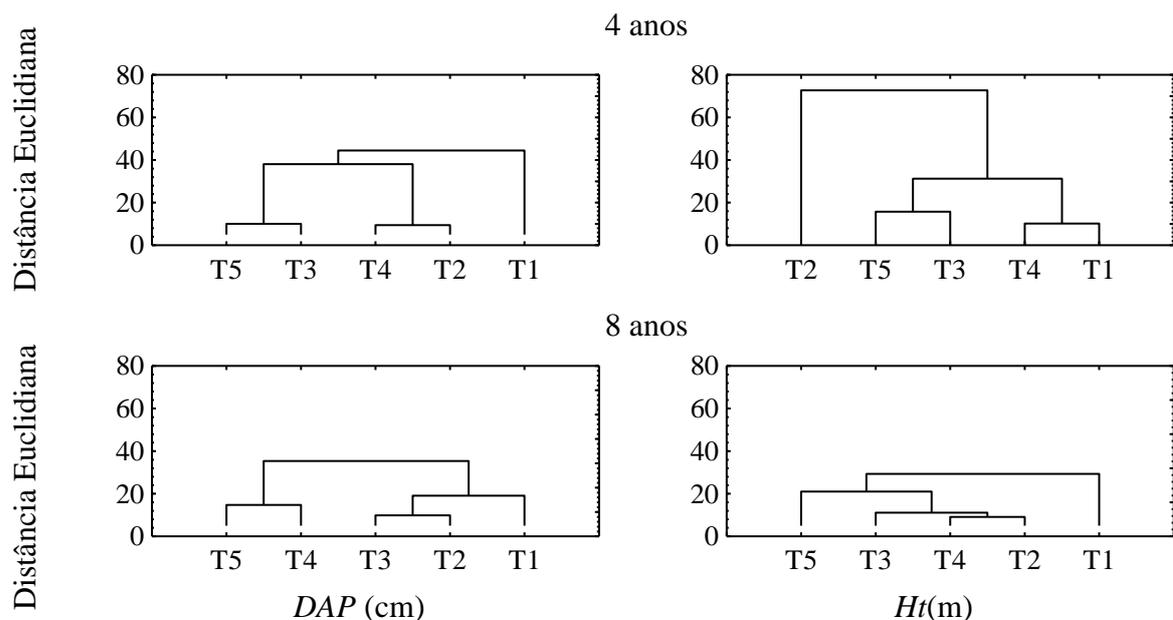


Figura 3. Análise de agrupamento de *DAP* e *Ht* em função dos tratamentos. Em que: T1 - 3,0 x 0,5 m; T2 - 3,0 x 1,0 m; T3 - 3,0 x 1,5 m; T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m.

O efeito estatístico significativo pelo teste F ($p < 0,05$) para tratamento foi observado em todas as fontes de variação, exceto para a proporção da casca e do lenho em relação ao tronco (Tabela 1). O espaçamento de plantio pode proporcionar um uso diferenciado dos nutrientes absorvidos pelo material genético. Os coeficientes de variação experimental foram muito baixos.

Tabela 1. Resumo da análise de variância da biomassa, volume e coeficiente de utilização biológico (CUB) por macronutriente e componente

Componentes	Casca	Lenho	Tronco	Casca	Lenho	Tronco
----- F.V. -----	----- Tratamentos (<i>p</i>) -----			----- CV exp(%) -----		
Volume		0,0060	0,0057		5,70	5,70
Proporção (%)	0,2611	0,2611		0,28	3,36	
B	0,0312	0,0275	0,0271	8,86	6,77	6,90
CUB _N	0,0002	0,0000	0,0000	5,35	2,84	2,07
CUB _P	0,0002	0,0000	0,0000	13,29	1,64	2,55
CUB _K	0,0017	0,0001	0,0009	6,95	1,78	1,94
CUB _{Ca}	0,0005	0,0000	0,0000	5,79	2,20	2,96
CUB _{Mg}	0,0010	0,0001	0,0000	5,62	1,66	2,01
CUB _S	0,0177	0,0000	0,0000	4,85	2,30	2,36

CV exp = Coeficiente de variação experimental; B = Biomassa.ha-1; os graus de liberdade foram 2, 4 e 8, respectivamente, para bloco, tratamento e resíduo. As equações de volume sem casca se encontram no apêndice (Tabela 1A). A densidade básica considerada para estimativa da biomassa de lenho foram, em média por tratamento, de T1 = 0,52; T2 = 0,55; T3 = 0,56; T4 = 0,56 e T5 = 0,55 g.cm⁻³. As equações para estimar o conteúdo de nutrientes de casca e lenho se encontram no apêndice (Tabela 2A).

Observou-se significância estatística em todos os parâmetros apresentados nas equações (Tabela 2) demonstrando a dependência do volume, da biomassa e do CUB para variações do espaçamento. A biomassa e volume aumentaram conforme diminuiu a distância entre plantas (Tabela 2 e Figura 4). A casca possui menor poder calorífico do que o lenho (Rocha, 2011). Conseqüentemente, em espaçamentos mais adensados a geração de energia será negativamente influenciada pela maior proporção de casca.

Os espaçamentos mais adensados foram mais produtivos (Figura 4). A viabilidade destes considerando rotações mais curtas deve ser avaliada considerando todos os custos e não somente em função da produção. Em muitos casos o aumento de produção não é suficiente para melhorar a viabilidade econômica do projeto, pois os custos de implantação e colheita podem ser muito impactados. Observando a tendência dos dados na Figura 4, principalmente quando o produto final desejado é o lenho os espaçamentos mais amplos são recomendados. Quando a viabilidade econômica considera como produto final o custo kw/h produzido esta tendência pode ser alterada (Müller, 2005; Rocha, 2011).

Tabela 2. Estatísticas dos ajustes realizados para estimação do volume, da biomassa e do coeficiente de utilização biológico (CUB) a partir da distância entre plantas

	----- Casca -----				----- Lenho -----				----- Tronco -----			
	β_0	β_1	β_2	\bar{R}^2	β_0	β_1	β_2	\bar{R}^2	β_0	β_1	β_2	\bar{R}^2
Vol	-	-	-	-	318,6	-26,7		0,6	323,7	-27,3		0,6
B	15,0	-1,3		0,3	171,4	-12,4		0,5	186,4	-13,8		0,4
CUB _N	152,9	182,4	-41,5	0,7	1772,6	-205,0		1,0	1010,4	187,8	-68,8	0,9
CUB _P	1377,8	1260,1		0,8	8738,2	3343,6	-866,7	0,9	6077,8	3361,5	-690,6	0,9
CUB _K	285,4	51,2		0,5	1167,4	172,1	-62,1	0,8	893,3	206,7	-57,7	0,8
CUB _{Ca}	87,9	41,2	-14,4	0,7	860,8	1235,4	-301,3	1,0	535,7	411,1	-117,7	0,9
CUB _{Mg}	740,3	102,9		0,5	8714,9	2172,5	-639,4	0,8	4135,3	1707,3	-388,1	0,9
CUB _S	2136,5	716,9	-216,3	0,3	3743,5	-297,1		0,8	3260,3	274,8	-152,9	0,9

Vol = Volume; B = Biomassa; número de observações = 15; \bar{R}^2 = coeficiente de determinação corrigido; $y = \beta_0 + \beta_1 D + \beta_2 D^2$ em que “D” foi a distância entre plantas e o “CUB_(kg de biomassa/ kg de nutriente)” ou “Volume_(m³/ha)” ou “Biomassa_(Mg/ha)” a variável dependente; todos os coeficientes foram significativos ($p < 0,01$); - = não se aplica.

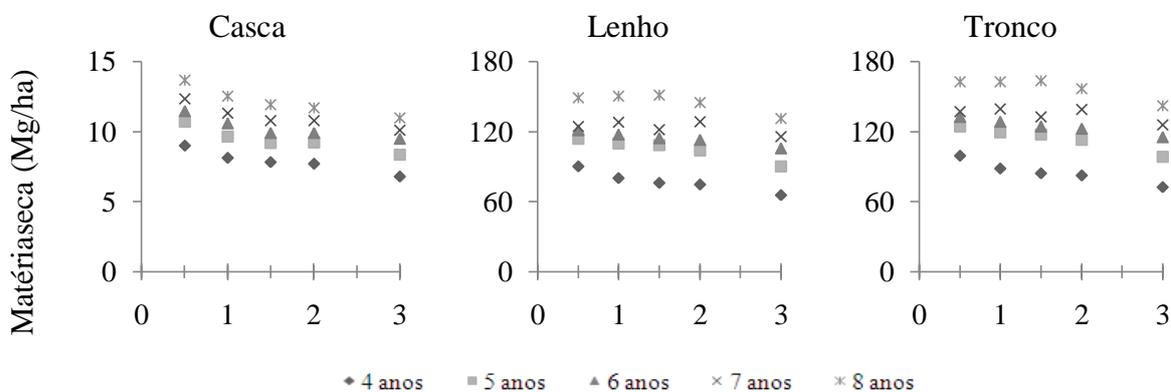


Figura 4. Comportamento da produção de biomassa ao longo dos anos e distâncias entre plantas em metros (eixo x).

O CUB decresceu no tronco sob o espaçamento 3,0 x 3,0 m na seguinte ordem: P > Mg > S > K > N > Ca. Fato que também foi registrado por Faria et al. (2008) e Santana et al. (2002). Enquanto isso, nos espaçamentos mais adensados ocorreu apenas a inversão de posição entre N e o K. Os valores críticos do CUB definidos pelo NUTRICAL (Barros, 1995) para produção de biomassa do tronco de eucalipto são: P = 12.000, K = 1.000, Ca = 600 e Mg = 3.000 kg de biomassa de tronco. kg de nutriente⁻¹. A amplitude de variação do CUB_K foi de 982 a 1076 e do CUB_P de 7586 a 10038 para os diferentes espaçamentos. Portanto estes nutrientes não limitaram a produção. O CUB_{Ca} variou de 709 a 887 e o CUB_{Mg} variou de 4892 a 5997 o que indica que estes foram os elementos que provavelmente limitaram o crescimento na rotação atual e poderá limitar a futura, a não ser que seja suprido via fertilizante em quantidades que atendam à demanda. Valores semelhantes de CUB encontrados neste estudo foram também observados por Santana et al. (2002) e Melo et al. (1995).

Não se tem estabelecido na literatura a eficiência crítica para o S e para o N pelo eucalipto. Observou-se que o CUB_S variou de 2709 a 3382 e CUB_N de 955 a 1137. Esta carência de estudos principalmente para o S pode, em parte, ser atribuída a sua condição de nutriente acompanhante em adubações (sulfato de amônio, superfosfato simples, sulfato de potássio e, entre outros). O valor crítico de eficiência permitiria estimar a quantidade de S a ser recomendada para se alcançar determinada produtividade em diferentes condições edafoclimáticas. Quanto ao N as respostas a aplicação deste nutriente são inconsistentes e quando se expressa esta ocorre nos anos iniciais de formação do povoamento (Pulito, 2009).

As variações observadas nos CUB's entre os espaçamentos (Tabela 2 e Figura 5) podem ter sido influenciadas pela plasticidade fenotípica intrínseca do próprio material genético sujeito a um ambiente competitivo conforme sugerido por Park et al. (2003). De acordo com Sieger et al. (2005) e Novais et al. (2007), a alteração dos processos fisiológicos de conversão dos nutrientes em biomassa são capazes de afetar o CUB. Essa adequação ao ambiente pode ocorrer devido aos processos fisiológicos, morfológicos e moleculares na planta que são induzidos por uma dada restrição imposta pela competição.

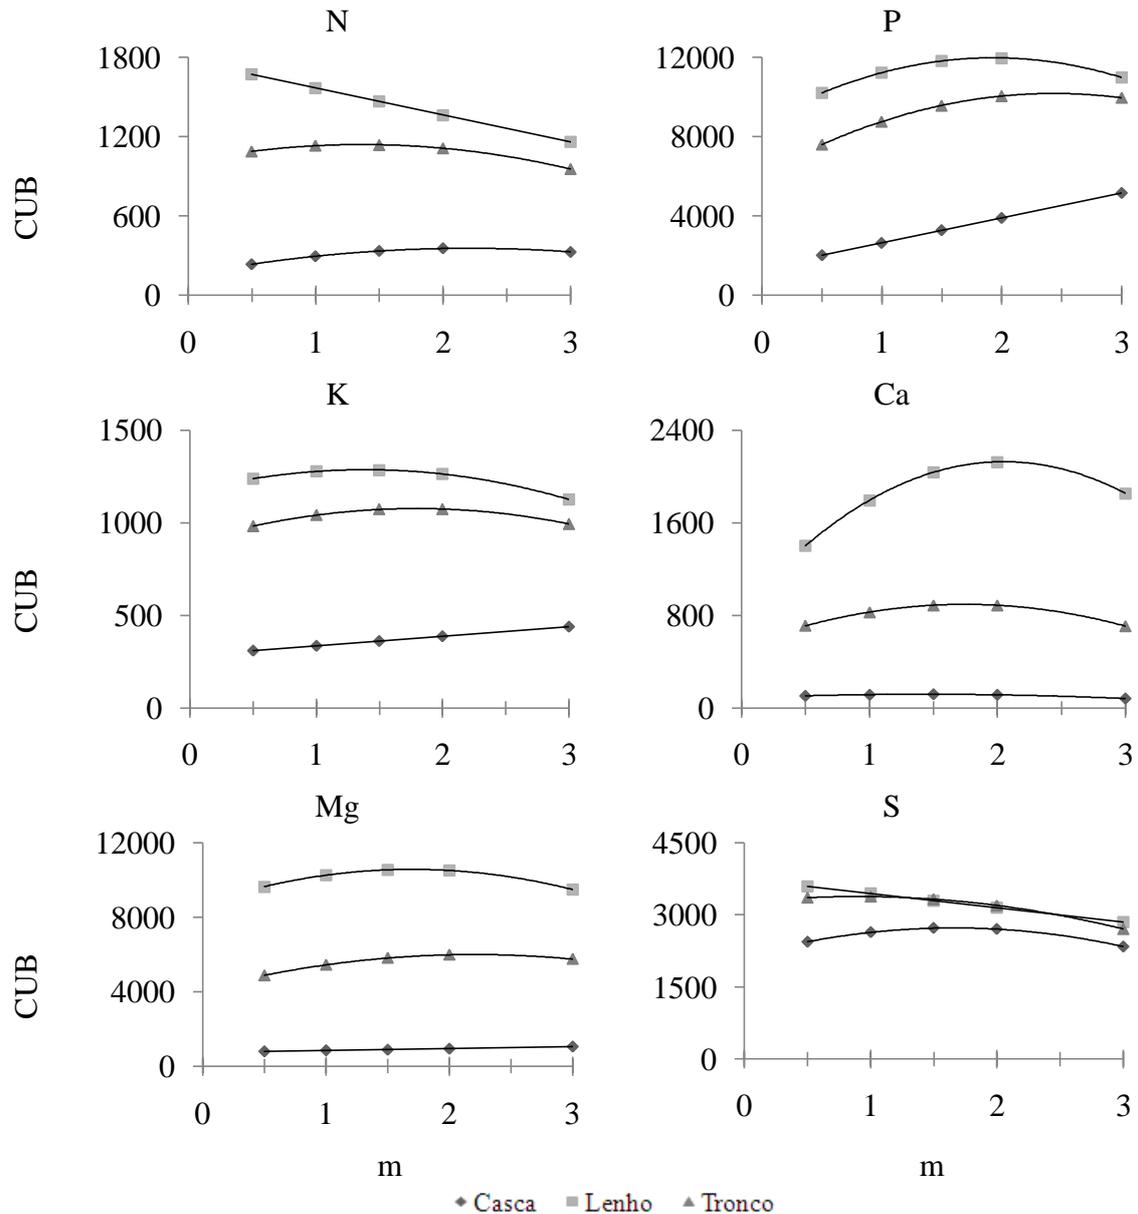


Figura 5. Coeficiente de utilização biológica dos macronutrientes para casca, lenho e tronco em função da distância entre plantas (as curvas apresentadas foram obtidas com as equações provenientes da (Tabela 2).

A maioria dos usos da madeira considera apenas o lenho como produto principal, por exemplo, carvão vegetal, mourões, caibros, móveis, etc.. Entretanto, a principal prática de colheita adotada no Brasil remove o tronco. No presente estudo a casca correspondeu a 7,8 % da matéria seca do tronco ou 12,8 Mg/ha, em média entre os espaçamentos. Esta é transportada para as indústrias e não é utilizada como principal produto, em muitas situações, geram resíduos que são passivos ambientais para as empresas. Se a colheita florestal optar apenas pelo lenho a eficiência de uso de todos os macronutrientes aumentaria expressivamente (Figura 5) resultando em economia na reposição de nutrientes em relação ao

uso do tronco de 60, 48, 26, 24, 22 e 9 %, respectivamente, para Ca, Mg, N, P, K, e S. Conseqüentemente a reposição de nutrientes exportados pela colheita, via fertilização, reduziria e melhor seria a sustentabilidade, conservação de nutrientes e água no solo e produtividade do sitio. A produtividade futura em sítios com limitações dos nutrientes mais exportados pode ser comprometida caso não seja adotado um correto manejo florestal e da fertilidade do solo (Santana et al., 2008). De forma geral, não houve expressiva variação no conteúdo de nutrientes entre os espaçamentos (Figura 6).

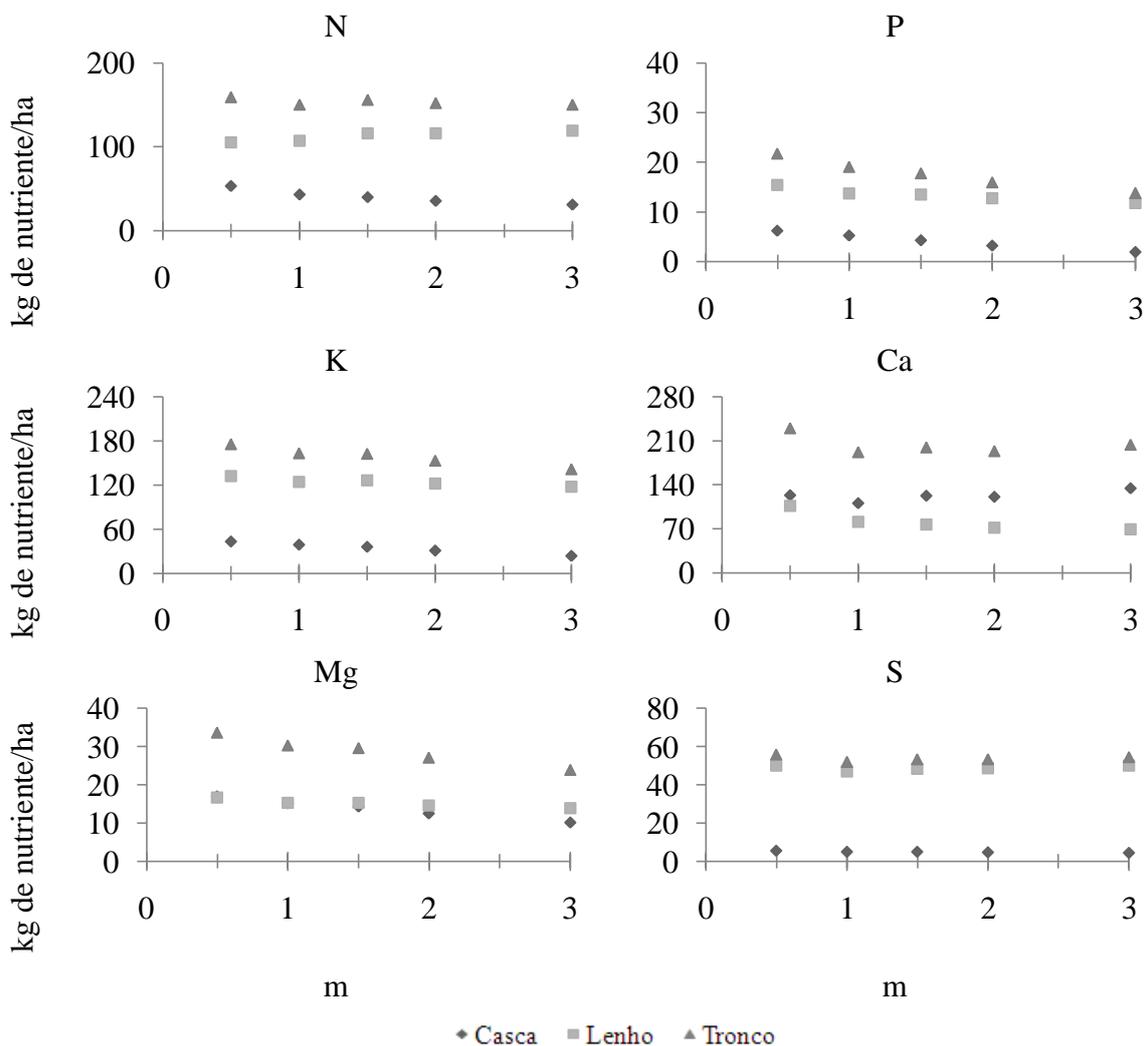


Figura 6. Conteúdo de macronutrientes nos componentes casca, lenho e tronco para cada distância entre plantas.

A estimação dos CUB's mediante o uso da inteligência artificial foi avaliada como alternativa a metodologia tradicionalmente utilizada. A arquitetura, entradas e funções de ativação da RNA utilizada são apresentadas na Tabela 3. Pelo treinamento das RNA obteve-se o comportamento não linear (exponencial) tanto na camada intermediária quanto na camada

de saída. Segundo Braga et al. (2007), este comportamento é frequentemente observado entre as MLP (*Multilayer Perceptron*).

Tabela 3. Características das redes neurais artificiais (RNA) selecionadas para projetar o coeficiente de utilização biológico no tronco (CUB_{Tronco})

TIPO	Arquitetura	----- Entradas -----		-- Função de Ativação --	
		Numéricas	Catégorica	Intermediária	Saída
MLP	9-7-1	<i>DAP, Ht</i>	NID	Exponencial	Exponencial
MLP	9-9-1	<i>DAP, Ht</i>	NID	Exponencial	Exponencial

n = 3828 linhas. NID = 1 – CUB_N , 2 – CUB_P , 3 – CUB_K , 4 – CUB_{Ca} , 5 – CUB_{Mg} e 6- CUB_S .

A modelagem obtida pelas redes por macronutriente foi capaz de estimar adequadamente os CUB 's dos macronutrientes para o tronco (Tabela 4 e Figura 7). Os indicadores de desempenho do modelo construído empregando a RNA resultaram em baixa tendenciosidade e desvios na calibração, no teste e na validação (Tabela 4) comprovando a semelhança das estimativas obtidas entre a RNA e o método tradicional. Pela análise gráfica foi verificada elevada correlação entre os valores estimados e observados e homogeneidade das variâncias dos CUB 's estimados com concentração da distribuição dos erros percentuais em torno de 10,0 % (Figura 7). Estes resultados indicam que uma rede pode ser utilizada para estimar os CUB 's dos macronutrientes de forma mais direta com uma única ferramenta estatística. Ao contrário, o uso dos métodos tradicionais implica em realização da ANOVA seguida por testes de médias e de regressão individualmente para cada componente, nutriente e estrato. Em muitos casos as análises por regressão não obtêm sucesso na estimativa dos CUB 's, estimativas estas obtidas pela rede.

Tabela 4. Precisão das redes neurais artificiais (RNA) para cada macronutriente

RNA	Fases	$RMSE_{\%}$	$Bias_{\%}$	Erros Relativos (%)			<i>p</i>
				Máximo	Médio	Mínimo	
1	Calibração	2,9589	-0,0401	30,4265	0,1676	-37,3390	0,5152
	Teste	2,9495	0,1509	27,2576	0,1392	-18,2671	
	Validação	0,9450	0,1208	12,0028	0,1563	-15,8801	
2	Calibração	3,2529	0,0141	23,8492	-0,0621	-44,1163	0,1078
	Teste	3,0919	0,2229	11,7435	-0,0473	-33,6403	
	Validação	0,8612	0,1498	12,9077	-0,0337	-8,6540	

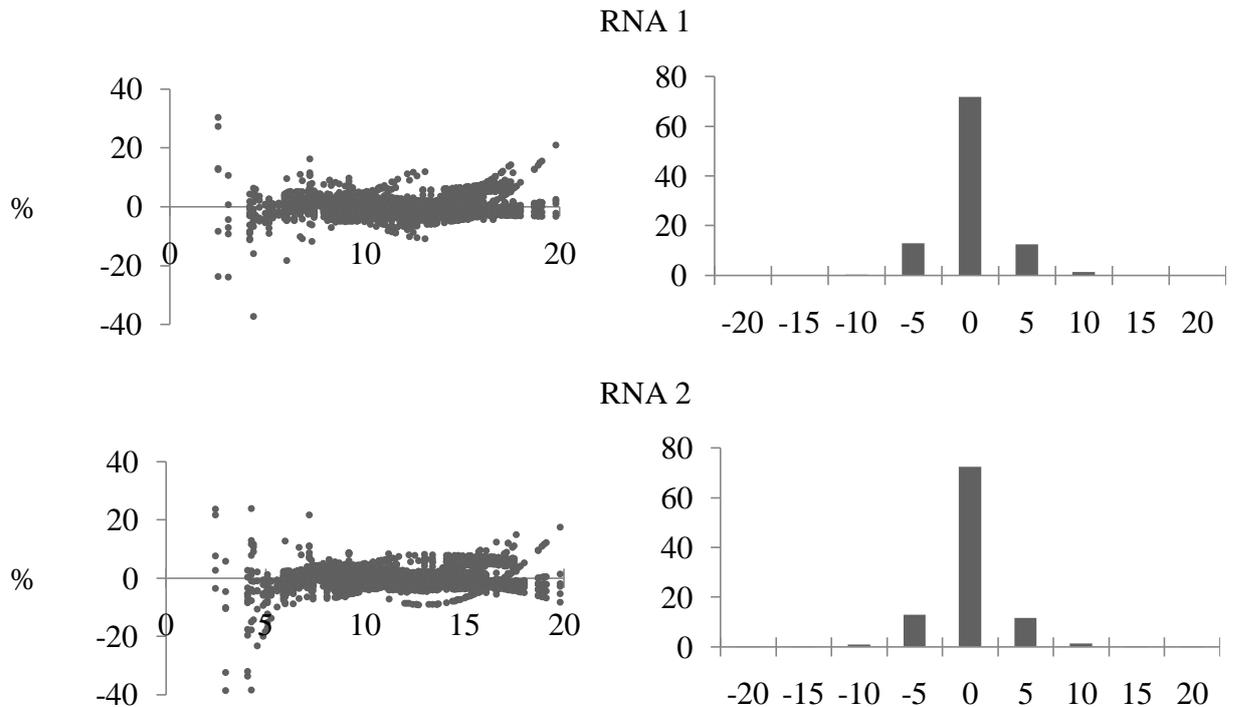


Figura 7. Distribuição dos resíduos percentuais dos coeficientes de utilização biológico (CUB, kg de biomassa/kg de nutriente) pela rede neural artificial diante do *DAP* e gráfico de dispersão observado *versus* estimado.

4. CONCLUSÕES

Não houve grande variação da eficiência de uso dos nutrientes entre os espaçamentos, principalmente para o tronco.

A rede neural artificial foi eficiente em estimar a eficiência de uso dos nutrientes.

5. REFERÊNCIAS BIBLIOGRÁFICAS

BARROS, N. F.; NOVAIS, R. F.; CARMO, D. N.; NEVES, J. C. L. Classificação nutricional de sítios florestais - Descrição de uma metodologia. **Revista Árvore**, v. 10, n. 2, p. 112-120, 1986.

BARROS, N. F.; NOVAIS, R. F.; TEIXEIRA, J. L.; FERNANDES FILHO, E; I. Nutricalc 2.0 – Sistema para cálculo del balance nutricional y recomendación de fertilizantes para el cultivo de eucalipto. **Bosque**, v. 16, n. 1, p. 129-131, 1995.

BINKLEY, D.; STAPE, J. L.; BAUERLE, W. L.; RYAN, M. G. Explaining growth of individual trees: Light interception and efficiency of light use by *Eucalyptus* at four sites in Brazil. **Forest Ecology and Management**, v. 259, p. 1704–1713, 2010.

BINOTI, M. L. M. S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 2010. 54f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa-Mg, 2010.

BINOTI, D. H. B.; LEITE, H. G.; NOGUEIRA, G. S.; SILVA, M. L. M.; GARCIA, S. L. R.; CRUZ, J. P. Uso da função Weibull de três parâmetros em um modelo de distribuição diamétrica para plantios de eucalipto submetidos a desbaste. **Revista Árvore**, v. 34, n.1, p. 147-156, 2010.

BRAGA, A. P.; CARVALHO, A. P.; LUDERMIR, T. B. **Redes neurais artificiais: Teoria e aplicações**. 2 ed. Rio de Janeiro: LTC, 2007. 226 p.

BREDOLAN, R. A.; PELLEGRINI, M. T.; ALVES, P. L. C. A. Effects of mineral nutrition on inter-and intra-specific competition of *Eucalyptus grandis* e *Brachiaria decumbens*: 1-plant growth. **Scientia Forestalis**, n. 58, p. 49-57, 2000.

CHAPIN, F. S. The mineral nutrition of wild plants. **Annual Review of ecology and systematic**. v.11, p. 233-260, 1980.

COELHO, L. S.; SILVA, W. V.; PROTIL, R. M. Previsão não-linear dos preços de troncos de eucalipto baseada em uma abordagem neuroevolutiva. **Gestão & Produção**, v. 14, n. 1, p. 139-154, 2007.

FARIA, G. E.; BARROS, N. F.; CUNHA, V. L. P.; MARTINS, I. S.; MARTINS, R. C. C. avaliação da produtividade, conteúdo e eficiência de utilização de nutrientes em genótipos de *Eucalyptus* spp. no Vale do Jequitinhonha, MG. **Ciência Florestal**, v. 18, n. 3, p. 363-373, 2008.

GORGENS, E. B.; LEITE, H. G.; SANTOS, H. N.; GLERIANI, J. M. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, v. 33, n. 6, p. 1141-1147, 2009.

HARRISON, R. B.; REIS, G. G.; REIS, M. G. F.; BERNARDO, A. L.; FIRME, D. J. Effect of spacing and age on nitrogen and phosphorus distribution in biomass of *Eucalyptus camaldulensis*, *Eucalyptus pellita* and *Eucalyptus urophylla* plantations in southeastern Brazil. **Forest Ecology and Management**, v. 133, n. 3, p. 167-177, 2000.

INMET – Instituto Nacional de Meteorologia. Disponível em: <<http://www.inmet.gov.br>>. Acesso em 16 de out. 2010.

LELES, P. S. S. L.; REIS, G. G.; REIS, M. G. F.; MORAIS, E. J. Crescimento, produção e alocação de matéria seca de *Eucalyptus camaldulensis* e *E. pellita* sob diferentes espaçamentos na região do cerrado, MG. **Scientia Forestalis**, n.59, p. 77-87, 2001.

LOPES, E. S.; CRUZINIANI, E.; DIAS, A. N.; FIEDLER, N. C. Avaliação técnica e econômica do corte de madeira de *Pinus* com cabeçote *harvester* em diferentes condições operacionais. **Floresta**, v. 37, n. 3, p. 305-313, 2007.

MABVURIRA, D.; MIINA, J. Individual-tree growth and mortality models for *Eucalyptus grandis*(Hill) Maiden plantations in Zimbabwe. **Forest Ecology and Management**, v. 161, p. 231-245, 2002.

MARTINS, F. B.; SOARES, C. P. B.; LEITE, H. G.; SOUZA, A. L.; CASTRO, V. O. Índices de competição em árvores individuais de eucalipto. **Pesquisa Agropecuária Brasileira**, v. 46, n. 9, p. 1089-1098, 2011.

MELO, V. F.; NOVAIS, R. F.; BARROS, N. F.; FONTES, M. P. F.; COSTA, L. M. Balanço nutricional, eficiência de utilização e avaliação da fertilidade do solo em P, K, Ca e Mg em plantios de eucalipto no Rio Grande do Sul. **IPEF**, n. 48/49, p. 8-17, 1995.

MÜLLER, M. D. **Produção de madeira para geração de energia elétrica numa plantação clonal de eucalipto em Itamarandiba-MG**. 2005. 94f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa-Mg, 2005.

NEVES, J. C. L. **Produção e partição de biomassa, aspectos nutricionais e hídricos em plantios clonais de eucalipto na região litorânea do Espírito Santo**. 2000. 191 f. Tese (Doutorado em Produção Vegetal) – Universidade Estadual do Norte Fluminense, Campo dos Goytacazes, Campo dos Goytacazes-RJ, 2000.

NOVAIS, R. F.; ALVAREZ, V. H.; BARROS, N. F.; FONTES, R. L. F.; CANTARUTTI, R. B.; NEVES, J. C. L. **Fertilidade do solo**. 1 ed. Viçosa: Sociedade Brasileira de Ciência do Solo, 2007. 1017 p.

PARK, S. E.; BENJAMIN, L. R.; WATKINSON, A. R. The theory and application of plant competition models: an agronomic perspective. **Annals of Botany**. v. 92, p. 741-748, 2003.

PULITO, A. N. **Resposta à fertilização nitrogenada e estoque de nitrogênio disponível em solos usados em plantações de *Eucalyptus***. Piracicaba, SP: ESALQ, 2009, 58p. Dissertação (Mestrado em Silvicultura e Manejo Florestal) – Escola Superior de Agricultura Luiz de Queiroz, Piracicaba-SP, 2009.

PULROLNIK, K.; BARROS, N. F.; SILVA, I. R.; NOVAIS, R. F.; BRANDANI, C. B. Estoques de carbono e nitrogênio em frações lábeis e estáveis da matéria orgânica de solos sob eucalipto, pastagem e cerrado no Vale do Jequitinhonha-MG. **Revista Brasileira de Ciência do Solo**, v. 33, p. 1125-1136, 2009.

ROCHA, M. F. V. **Influência do espaçamento e da idade na produtividade e propriedades da madeira de *Eucalyptus grandis* x *Eucalyptus camaldulensis* para energia**. 2011. 71 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa-MG, 2011.

SANTANA, R. C.; BARROS, N. F.; NEVES, J. C. L. Biomassa e conteúdo de nutrientes de procedências de *Eucalyptus grandis* e *Eucalyptus saligna* em alguns sítios florestais do Estado de São Paulo. **Scientia Forestalis**, n. 56, p. 155-169, 1999.

SANTANA, R. C.; BARROS, N. F.; NEVES, J. C. L. Eficiência de utilização de nutrientes e sustentabilidade da produção em procedências de *Eucalyptus grandis* e *Eucalyptus saligna* em sítios florestais do estado de São Paulo. **Revista Árvore**, Viçosa-MG, v.26, n.4, p.447-457, 2002.

SANTANA, R. C.; BARROS, N. F.; NOVAIS, R. F.; LEITE, H. G.; COMERFORD, N. B. Alocação de nutrientes em plantios de eucalipto no Brasil. **Revista Brasileira de Ciência do Solo**, v. 32, p. 2723-2733, 2008.

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

SIEGER, S. M.; KRISTENSEN, B. K.; ROBSON, C. A.; AMIRSADEGHI, S.; ENG, E. W.; ABDEL-MESIH, A.; MOLLER, I. M.; VANLERBERGHE. The role of alternative oxidase in modulating carbon use efficiency and growth during macronutrient stress in tobacco cells. **Journal of Experimental Botany**, v.56, n. 416, p. 1499–1515, 2005.

SKOVSGAARD, J. P. VANCLAY, J. K. Forest site productivity: a review of the evolution of dendrometric concepts for even-aged stands. **Forestry**, v. 81, n. 1, p. 13-31, 2008.

STAPE, J. L.; BINKLEY, D.; RYAN, M. G.; FONSECA, S.; LOOS, R. A.; TAKAHASHI, E. N.; SILVA, C. R.; SILVA, S. R.; HAKAMADA, R. E.; FERREIRA, J. M. A.; LIMA, A. M. N.; GAVA, J. L.; LEITE, F. P.; ANDRADE, H. B.; ALVES, J. M.; SILVA, G. G. C.; AZEVEDO, M. R. The Brazil *Eucalyptus* potential productivity project: Influence of water, nutrients and stand uniformity on Wood production. **Forest Ecology and Management**, v. 259, p. 1684-1694, 2010.

VITAL, B. R. **Métodos de determinação da densidade da madeira**. Viçosa, MG: Sociedade de Investigações Florestais, 1984. 21 p.

STATSOFT, INC. Statistica (data analysis software system), version 7. Disponível em: <[http://www.statsoft .com](http://www.statsoft.com)>, 2007.

WOODRUFF, D.R.; BOND, B.J.; RITCHIE, G.A.; SCOTT, W. Effects of stand density on the growth of young Douglas-fir trees. **Canadian Journal of Forest Research**, v. 32, n. 3, p. 420-427, 2002.

CAPÍTULO 3

EFICIÊNCIA DE UTILIZAÇÃO DE MACRONUTRIENTES EM EUCALIPTO POR MÉTODO NÃO DESTRUTIVO ESTIMADOS POR REDES NEURAS ARTIFICIAIS

RESUMO – A amostragem não destrutiva (AND) permite uma caracterização eficiente, simples e segura das propriedades químicas do vegetal, como o coeficiente de utilização biológico. A associação da AND com a técnica de redes neurais artificiais (RNA) pode ser uma alternativa potencial em substituição às equações de regressão e aos métodos tradicionais de interpolação. Portanto, o presente trabalho objetivou avaliar a eficiência da RNA e da amostragem não destrutiva para estimar a eficiência de uso de nutrientes no tronco. O experimento foi instalado em blocos ao acaso sendo estudado, em três blocos, o efeito de cinco espaçamentos de plantio: T1 - 3,0 x 0,5 m; T2 - 3,0 x 1,0 m; T3 - 3,0 x 1,5 m; T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m. Uma árvore-amostra foi abatida para realizar a cubagem rigorosa e quantificar a matéria seca de casca e lenho por unidade experimental, totalizando-se 15 árvores. As árvores-amostras foram pesadas no campo e subamostras de casca e lenho foram coletadas ao longo do fuste para compor uma amostra composta por árvore. Também foi retirada uma amostra simples de cada componente obtidas com auxílio de um formão e martelo na região do *DAP* nas mesmas árvores-amostras. As amostras foram secas a 65 °C até peso constante. O material vegetal foi moído e submetido análise química de N, P, K, Ca, Mg e S. Ajustaram-se modelos de regressão e aplicação de RNA para estimação do CUB_{Tronco} a partir do $CUB_{DAP\ Casca}$ e $CUB_{DAP\ Lenho}$. As RNA apresentaram maior precisão e confiabilidade do que a regressão. Concluiu-se que a modelagem por redes neurais artificiais utilizando-se apenas uma amostra da casca na região do *DAP* demonstrou ser adequada para a estimativa do coeficiente de utilização biológico do tronco.

Palavras-chave: CUB; RNA; Amostragem não destrutiva; Densidade de plantio; Florestas energéticas.

MACRONUTRIENTS USE EFFICIENCY IN EUCALYPTUS BY DESTRUCTIVE METHODS ESTIMATED BY ARTIFICIAL NEURAL NETWORKS

ABSTRACT – The non-destructive sampling (AND) provides a characterization efficient, simple and safe of chemical properties of the plant, as the coefficient of use biological. The association of AND with the technique of artificial neural networks (RNA) can be a potential alternative to replace the regression equations and traditional methods of interpolation. Therefore, this work aimed to evaluate the efficiency of RNA and non-destructive sampling for the efficiency of nutrient use in the trunk. The research plot was installed in randomized block being studied, in three blocks, the effect of five planting spacings: T1 – 3,0 x 0,5 m, T2 – 3,0 x 1,0 m, T3 – 3,0 x 1,5 m, T4 – 3,0 x 2,0 m e T5 – 3,0 x 3,0 m. A sample-tree was felled to make the cubage and quantify the dry bark and wood per experimental plot, totaling 15 trees. The sample-trees were weighed in the field and subsamples of bark and wood were collected along the stem to form a composite sample per tree. Also removed was a single sample of each component obtained with the aid of a chisel and hammer in DAP in the same sample-trees. The samples were dried at 65 ° C until constant weight. The material was ground and subjected chemical analysis of N, P, K, Ca, Mg and S. Adjusted regression models and application of RNA to estimation of CUB_{Trunk} , $CUB_{DAP Bark}$ and $CUB_{DAP Wood}$. The RNA had a higher accuracy and reliability of the regression. It was concluded that modeling by artificial neural networks using only sample in the DAP region proved to be adequate for estimating the coefficient of biological use of stem.

Key words: CUB; RNA; Non-destructive sampling; Planting density; Energy forests.

1. INTRODUÇÃO

A produtividade de uma floresta pode ser influenciada pela fertilização, principalmente, em condições tropicais que possui solos muito intemperizados. A definição da quantidade de nutrientes aplicada pode ser realizada por diferentes métodos. Um ponto crítico na definição de fertilizações pauta-se na quantificação dos nutrientes que são exportados do sítio pela colheita, pois para se ter um sistema sustentável o nutriente exportado deverá ser repostado. A relação entre produção de biomassa e conteúdo de nutrientes contidos nesta é bem conhecida. Segundo Santana et al. (2008), a distribuição relativa de macronutrientes e de biomassa na parte aérea de eucalipto ao longo dos anos aumenta linear e proporcionalmente.

A reposição de nutrientes exportados pela colheita poderá variar em função da intensidade de uso do solo, dos componentes da biomassa que são colhidos e pela interação dos fatores que afetam a produtividade como a disponibilidade da água, energia radiante, temperatura e gás carbônico (Almeida et al., 2007; Costa et al., 2009; Mendes et al., 2010). A adoção de práticas silviculturais pode ser diferenciada entre materiais genéticos diante à definição da sua exigência e tolerância ao déficit de nutrientes.

A eficiência de utilização de nutriente pode ser definida como quantidade de matéria seca produzida por grama do nutriente ou o inverso da concentração do nutriente nos tecidos (Chapin, 1980), ou ainda, como o coeficiente de utilização biológico dos nutrientes (CUB). O CUB é uma medida ecológica que integra uma variedade de processos fisiológicos, bem como, a forma em que os nutrientes absorvidos pelas plantas são geralmente usados para a produção de biomassa (Alongi et al., 2005), podendo ser usado para auxiliar a seleção de materiais genéticos indicados em diferentes condições edafoclimáticas e para a recomendação de fertilizantes (Barros et al., 1986; Barros et al., 1995).

O conhecimento do CUB é importante para seleção de genótipos e indicar o tipo de solo mais adequado para a sua adaptação e crescimento. Conhecendo-se o CUB de um nutriente e a expectativa de produção de biomassa é possível estimar a quantidade de nutrientes necessária para um adequado balanço nutricional do próximo ciclo (Saideles et al., 2010), sendo este o método mais utilizado para estimar a reposição de nutrientes em plantações de eucalipto.

Atualmente, essa eficiência é obtida abatendo-se árvores-amostras, quantificando a matéria seca e realizando análises químicas de nutrientes em amostras compostas dos seus

componentes. Após a fase destrutiva calcula-se o CUB e a partir de então este valor é utilizado para estimar a demanda de nutrientes, pois pelo inventário florestal é possível obter estimativas precisas de biomassa. Entretanto, podem ocorrer variações na eficiência para um mesmo material genético em função das condições edafoclimáticas (Santana et al., 2002) exigindo constante aferição do CUB. Considerando a escala operacional das grandes empresas florestais, esta aferição é muito importante para obter adequada produção e otimizar a aplicação de fertilizantes. O custo da amostragem destrutiva sempre é superior ao que se pode obter por processos não destrutivos e este aumenta à medida que se amplia a área a ser amostrada.

Na busca por novas opções para caracterização eficiente, simples e segura das propriedades químicas do vegetal, destacam-se as avaliações não destrutivas (AND). Nestas, as informações sobre o material de interesse são obtidas por medidas indiretas, sendo versátil para se adequar a uma rotina adotada operacionalmente, reduzindo o volume de trabalho, tempo e custo. A obtenção do CUB empregando-se apenas uma amostra de determinada posição na árvore pode não ser representativa, visto que, o teor de nutrientes pode variar ao longo do fuste das árvores conforme mobilidade de redistribuição característica de cada nutriente (Saideles et al., 2010). Entretanto, essa diferença pode ser corrigida parametrizando através da associação da AND com métodos matemáticos e, também, validada pelo método tradicional destrutivo.

Existem diversas ferramentas de natureza estatística que podem ser adotadas para auxiliar no processamento de dados oriundos da AND, dentre as mais empregadas estão a regressão e a interpolação. Embora a estimação por regressão permita a determinação de uma equação que expresse o comportamento de uma dada variável dependente com menos complexidade e fácil interpretação, pode haver situações que estas são incapazes de denotar esse desempenho pela falta de qualidade no ajustamento ou ausência do mesmo.

A inteligência artificial é uma técnica que permite análises flexíveis e obtenção de estimativas confiáveis. Seu uso é crescente e proporciona adequados resultados na Ciência Florestal como, por exemplo, na estimação de volume, altura de árvores e na modelagem do crescimento e produção florestal (Gorgens et al., 2009; Binoti, 2010)

As redes neurais artificiais (RNA, *Artificial Neural Network*) ou conexionismo são modelos computacionais que simulam grosseiramente a estrutura, o processamento de informações e a aquisição de conhecimento do cérebro humano e sistema nervoso, apresentando uma memória associativa e distribuída capaz de estabelecer relações entre variáveis independentes para estimar variáveis dependentes (Coelho et al., 2007).

Matematicamente, é um sistema massivo e paralelo cujas unidades de processamento simples são os neurônios artificiais, dispostos em uma ou mais camadas e interligados entre si com ponderações ajustáveis por um grande número de conexões (Gorgens et al., 2009; Bullinária, 2011). Integrando as seguintes características: analogia neurobiológica, mapeamento de entrada e saída, tolerância a falhas e ruídos, adaptabilidade dos pesos das conexões às modificações do ambiente e generalização do conhecimento assimilado por aprendizagem para um conjunto de dados desconhecidos (Binoti, 2010).

Conforme exposto, a AND permite analisar um maior número de informações e estabelecer critérios práticos de caracterização e classificação do material vegetal com uma dada precisão, cuja associação com a técnica de redes neurais artificiais pode ser uma alternativa potencial em substituição às equações de regressão e aos métodos tradicionais de interpolação, conforme descrito por Silva e Cecílio (2010). Portanto, o presente trabalho objetivou avaliar a eficiência da RNA e da amostragem não destrutiva para estimar a eficiência de uso de nutrientes no tronco.

2. MATERIAL E MÉTODOS

O estudo foi conduzido a 17° 50' de latitude sul e 42° 49' de longitude oeste em área da Aperam Bioenergia, antiga ACESITA Energética, no município de Itamarandiba-MG. O clima predominante na região é do tipo Cwa, segundo a classificação de Köppen, com verões quentes e chuvosos e invernos amenos e secos com estação seca bem definida de abril a setembro e déficit hídrico mensal de 30 a 50 mm (INMET, 2010) e com médias anuais de temperatura e precipitação pluviométrica de 20 °C e 1160 mm, respectivamente (Pulrolnik et al., 2009).

O experimento foi instalado em dezembro de 2002 utilizando-se um híbrido de *Eucalyptus grandis* W. Hill ex Maiden x *Eucalyptus camaldulensis* Dehnh sobre Latossolo Vermelho-Amarelo em relevo plano a 1097 m altitude. Adotou-se delineamento em blocos, com três blocos, sendo estudado o efeito de cinco tratamentos constituídos pelos seguintes espaçamentos de plantio: T1 - 3,0 x 0,5 m; T2 - 3,0 x 1,0 m; T3 - 3,0 x 1,5 m; T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m, sendo 3 m a distância fixa entre linhas de plantio. Em cada tratamento foram estabelecidas seis linhas de plantio com 28 árvores, totalizando 168 indivíduos, dos quais 48 foram mensurados, por ter sido adotada a bordadura dupla.

Aos oito anos de idade mensurou-se o diâmetro a 1,30 m de altura do solo (*DAP*) e altura total (*Ht*) de todas as árvores. Uma árvore-amostra, árvore com diâmetro médio quadrático, foi abatida para realizar a cubagem rigorosa empregando-se o método de Smalian e para quantificar a matéria seca de casca e lenho por unidade experimental, totalizando 15 árvores. As árvores-amostras foram pesadas no campo e subamostras de casca e lenho foram coletadas ao longo do fuste para compor uma amostra composta por árvore. Também foi retirada uma amostra simples de cada componente obtidas com auxílio de um formão e martelo no *DAP* nas mesmas árvores-amostras. As dimensões da casca foram de 10,0 x 10,0 cm e do lenho de 5,0 x 10,0 cm, cujo comprimento foi no sentido vertical, e de, aproximadamente, 2,5 cm de profundidade interiorizando no lenho. As amostras foram secas a 65 °C até peso constante em estufa com circulação forçada de ar. O material vegetal foi moído e submetido à digestão nítrico-perclórica para realizar a análise química de macronutrientes. Os teores de P foram determinados por colorimetria, de K por fotometria de emissão de chama, de S por turbidimetria, Ca e Mg por espectrofotometria de absorção atômica. O N total foi determinado pelo método Kjeldhal após digestão sulfúrica.

O CUB do tronco foi calculado pela relação Kg matéria seca por Kg de nutrientes e foi denominado “CUB_{Tronco}” para cada macronutriente. Como o CUB pode ser obtido pelo inverso da concentração do nutriente, foi estimado utilizando-se o resultado analítico obtido pela amostragem pontual de casca e lenho no *DAP*. Estes dados foram utilizados para estimar o CUB_{Tronco} pelo seguinte modelo:

$$\text{Modelo 1: } CUB_{Tronco_x} = \beta_0 + \beta_1 CUB_{DAPCasca_x} + \beta_2 CUB_{DAPLenho_x} + \varepsilon,$$

em que x = nutriente (N, P, K, Ca, Mg, S) e ε = erro aleatório.

Em função da possível falta de ajuste pela regressão quando se relaciona um ponto do tronco em relação à amostragem por toda a sua extensão, incorporou-se mais variáveis independentes para estimar o CUB_{Tronco} pelo método Stepwise backward. Os *inputs* analisados foram assim definidos: CUB no *DAP* para a casca e lenho, *DAP* sem casca_(cm) (*DAP_{sc}*), espessura da casca_(cm), *DAP_{sc}*/*DAP*, espessura da casca/*DAP*, *DAP*_(cm) e *Ht*_(m).

Almejando-se obter um modelo generalista para o CUB do tronco, os macronutrientes foram agrupados em uma única variável denominada *NID* e assim categorizados N – 1; P – 2; K – 3; Ca – 4; Mg – 5 e S – 6. É importante salientar o uso restrito a este trabalho das equações geradas pelos modelos 2 e 3, cuja finalidade foi comparativa do desempenho das redes neurais artificiais com a regressão de forma direta e que integre os macronutrientes analisados em um único modelo estatístico:

Modelo 2 (GT): $CUB_{Tronco_x} = \beta_0 + \beta_1 CUB_{DAPCasca_x} + \beta_2 CUB_{DAPLenho_x} + \beta_3 NID_x + \varepsilon$,

Modelo 3 (GC): $CUB_{Tronco_x} = \beta_0 + \beta_1 CUB_{DAPCasca_x} + \beta_2 NID_x + \varepsilon$,

em que $x =$ nutriente (N, P, K, Ca, Mg, S) e $\varepsilon =$ erro aleatório.

Estimaram-se os CUB's para cada modelo pelo método dos mínimos quadrados ordinários (MQO) utilizando o procedimento iterativo Levenberg-Marquardt e por redes neurais artificiais (RNA).

O treinamento de uma rede neural artificial, também denominado aprendizagem, consiste no ajuste dos parâmetros da rede (pesos e *bias*) através de um algoritmo de aprendizagem. Neste processo os dados de treinamento (conjunto de exemplos) são apresentados a uma arquitetura pré-estabelecida, ou seja, um determinado número de arranjos de neurônios em camadas. E o algoritmo de treinamento extrai características a fim de representar a informação fornecida e desempenhar uma determinada tarefa. As variáveis utilizadas como entrada das RNA para estimação dos CUB's por macronutriente foram numéricas e categórica conforme modelos 1, 2 e 3.

Como possível alternativa ao método de regressão na AND, foram utilizadas redes anteroalimentadas (*feedforward*), treinadas por meio do algoritmo da retropropagação do erro (*backpropagation*), ou seja, durante o treinamento da rede foram realizados cálculos partir da camada de entrada da rede para a de saída e o erro propagado para camadas anteriores. Em todos os pré-processamentos foi realizada a normalização e equalização dos dados visando uma maior sensibilidade da rede à variação dos mesmos e captar melhor seu comportamento. Os dados foram divididos em grupos de calibração (60,0 % das amostras), validação (20,0 %) e teste (20,0 %), utilizando o método randômico de amostragem.

Foram treinadas 800 RNA do tipo *Multilayer Perceptron* (MLP): 600 para estimar o CUB_{Tronco} conforme modelo 1 (100 para cada macronutriente) e 100 para cada modelo restante (modelos 2 e 3). Destas foram selecionadas duas com base nos desvios dos valores estimados e observados, sendo, portanto, selecionadas 16 redes para o estudo. A escolha do tipo MLP está relacionada à atribuição de uma maior complexidade das RNA face ao maior número de entradas, o que aumenta o número de parâmetros ajustados conforme Braga et al. (2007). A definição da arquitetura das redes, ou seja, número de camadas e o número de neurônios por camada foi otimizada pela ferramenta *Intelligent Problem Solver* (IPS) do *software* Statistica 7.0 (Statsoft, 2007).

A avaliação da acurácia e precisão das equações ajustadas e do resultado do treinamento das redes neurais artificiais foram realizadas por meio do *erro%*, teste de *RMSE%*,

teste de $Bias\%$ e análise de resíduos percentuais. As estimativas das técnicas estatísticas relacionadas à regressão e das RNA foram comparadas por meio do teste t pareado a 5,0 % de probabilidade com os valores observados, conforme Gorgens et al. (2009). O erro foi assim definido $erro_{\%} = ((\hat{y} - y)/y)100$, enquanto que a raiz do quadrado médio do erro ($RMSE_{\%}$) e a tendenciosidade ($Bias_{\%}$) foram determinadas segundo Mabvurira & Miina (2002): $RMSE_{\%} = 100 \left(\sqrt{\sum(y_i - \hat{y}_i)^2 / (n - 1)} \right) / (\sum \hat{y}_i / n)$ e $Bias_{\%} = 100 ((\sum(y_i - \hat{y}_i)) / n) / (\sum \hat{y}_i / n)$, em que y_i e \hat{y}_i são os valores observados e preditos, respectivamente.

Os ajustes dos modelos de regressão e treinamento das RNA foram realizados com auxílio do *software* Statistica 7.0 (Statsoft, 2007).

3. RESULTADOS E DISCUSSÃO

As equações provenientes dos ajustes referentes aos modelos 1, 2 e 3 são apresentadas na Tabela 1. Os coeficientes de determinação das equações ficaram próximos à unidade e os parâmetros associados a todas variáveis independentes apresentaram elevada significância estatística. Entre as variáveis avaliadas pela Stepwise, a relação diâmetro do lenho com o *DAP* foi a melhor para as estimativas dos CUB's individuais para N, P, K e Ca. Para o Mg foi a relação espessura da casca com *DAP* e para o S mais de uma variável explicativa. A variável categórica para as equações generalistas mostrou-se eficiente porque apresentou alta significância. Verificaram-se melhorias na precisão estatística ao incorporar entradas dendrométricas no modelo de estimação do CUB na região do tronco, haja vista que os maiores coeficientes de determinação foram observados para as equações específicas por macronutriente.

A semelhança dos dados estimados e observados pelas regressões foi evidenciada pela ausência de significância estatística no teste t pareado (Tabela 2). As equações para estimação do CUB_{Tronco} do N, Mg e S apresentaram os menores desvios expressos pela $RMSE_{\%}$, tendenciosidades e erros relativos médios. A utilização da regressão como ferramenta estatística para criar uma equação generalista para todos os macronutrientes categorizados não apresentou adequada acurácia e precisão (GT e GC), apesar de ter apresentado baixo $Bias_{\%}$. A precisão das equações para estimação dos CUB's (Tabela 2) não foi comprovada pela análise gráfica, pois a maioria foi heterocedástica (Figura 1).

Tabela 1. Equações para estimar o CUB_{Tronco} para macronutrientes

	n	Equações ajustadas	\bar{R}^2
N	15	$CUB_{Tronco} = 929,67^{**} \left(\frac{DAP_{sc}}{DAP} \right)$	0,992
P	15	$CUB_{Tronco} = -74125,19^* + 86851,52^* \left(\frac{DAP_{sc}}{DAP} \right)$	0,967
K	15	$CUB_{Tronco} = 902,01^{**} \left(\frac{DAP_{sc}}{DAP} \right)$	0,968
Ca	15	$CUB_{Tronco} = 733,50^{**} \left(\frac{DAP_{sc}}{DAP} \right)$	0,968
Mg	15	$CUB_{Tronco} = 8003,18^{**} - 54974,87^{**} \left(\frac{espessura\ da\ casca}{DAP} \right)$	0,980
S	15	$CUB_{Tronco} = 0,74^{**} CUB_{DAPLenho} + 192,46^{**} Ht - 338,44^{**} DAP$	0,989
GT	90	$CUB_{Tronco_x} = 0,24^{**} CUB_{DAPLenho_x} + 0,67^{**} CUB_{DAPCasca_x} + 158,21^{**} Nid_x$	0,946
GC	90	$CUB_{Tronco_x} = 1,71^{**} CUB_{DAPCasca_x} + 219,07^{**} Nid_x$	0,875

N, P, K, Ca, Mg, S foram obtidos pelo Modelo 1/Stepwise; GT = Modelo 2; GC = Modelo 3; ⁿ número de observações; x = N, P, K, Ca, Mg ou S; ^{**} significativo a 1,0 %; ^{*} significativo a 5,0 %; \bar{R}^2 = coeficiente de determinação corrigido; Espessura de casca; DAP e DAP_{sc} expressos em cm. CUB expresso em Kg de biomassa. Kg de nutriente⁻¹.

Tabela 2. Precisão das equações obtidas para os CUB's do tronco

CUB	RMSE%	Bias%	Erros Relativos (%)			Teste t p
			Máximo	Médio	Mínimo	
N	8,40	0,00	14,46	0,66	-12,44	0,9990
P	18,60	0,00	38,36	3,12	-26,98	1,0000
K	18,21	-0,09	60,33	3,74	-24,43	0,9857
Ca	18,20	-0,08	50,28	3,54	-24,20	0,9870
Mg	14,33	0,00	49,92	2,27	-22,69	1,0000
S	10,58	0,43	14,22	-0,55	-19,92	0,8764
GT	31,05	-1,08	165,84	19,28	-43,26	0,7413
GC	49,05	2,06	159,69	19,51	-67,70	0,6908

^{ns}($p > 0,05$) no teste t pareado. GT = Modelo 2; GC = Modelo 3.

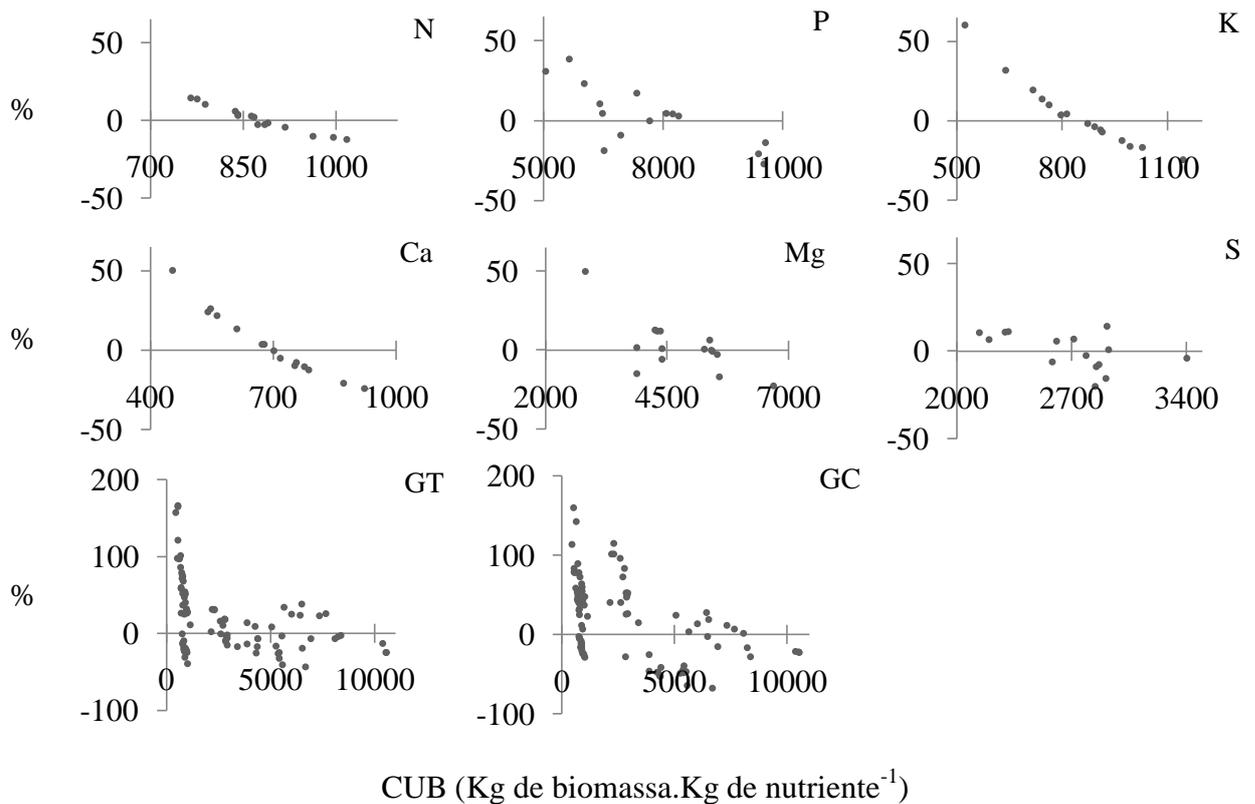


Figura 1. Distribuição dos resíduos percentuais (eixos y) em função dos CUB's no tronco (eixos x, kg de biomassa/kg de nutriente) pelas regressões.

A maioria das redes apresentou funções de ativação de base não linear nas camadas intermediárias e de saída (Tabela 3). Maior complexidade foi observada para as redes generalistas que apresentaram mais neurônios nas camadas intermediárias.

As amplitudes de variação do $RMSE_{\%}$ entre as fases de treino, teste e validação observadas nas redes por nutriente foram muito superiores às das redes generalistas (Tabela 4). Diante da semelhança observada entre os valores de $RMSE_{\%}$, $Bias_{\%}$ e Erros Relativos (%) dentro de um mesmo tipo de rede, a escolha da melhor rede baseou-se nas probabilidades do teste t . Estas probabilidades para as redes generalistas e por nutriente apresentaram semelhança entre si superior a 70 % para GC, P e Mg, consequentemente, procedeu-se a análise gráfica destas (Figura 2). Para o N, K, Ca, S e GT optaram-se apenas pela análise gráfica da melhor rede, pois as RNA N2, K1, Ca1, S2 e GT2 apresentaram uma probabilidade inferior a 70%, comparativamente à sua correspondente.

As estimativas do CUB_{Tronco} obtidas pelas RNA comparativamente às das regressões foram mais precisas (Tabelas 2 e 4), além da tendência à homocedasticidade (Figura 2).

Tabela 3. Características das redes neurais artificiais (RNA) selecionadas para projetar o CUB_{Tronco} dos macronutrientes

RNA	n	TIPO	Arquitetura	----- Entradas -----		-- Função de Ativação --	
				Num	Catagórica	Intermediária	Saída
N1	MLP	2-8-1	15	$CUB_{DAP\ Casca}$, $CUB_{DAP\ Lenho}$		Tangencial	Identidade
N2	MLP	2-6-1	15	$CUB_{DAP\ Casca}$, $CUB_{DAP\ Lenho}$		Tangencial	Identidade
P1	MLP	2-9-1	15	$CUB_{DAP\ Casca}$, $CUB_{DAP\ Lenho}$		Logística	Logística
P2	MLP	2-5-1	15	$CUB_{DAP\ Casca}$, $CUB_{DAP\ Lenho}$		Logística	Logística
K1	MLP	2-3-1	15	$CUB_{DAP\ Casca}$, $CUB_{DAP\ Lenho}$		Logística	Logística
K2	MLP	2-3-1	15	$CUB_{DAP\ Casca}$, $CUB_{DAP\ Lenho}$		Tangencial	Logística
Ca1	MLP	2-9-1	15	$CUB_{DAP\ Casca}$, $CUB_{DAP\ Lenho}$		Tangencial	Exponencial
Ca2	MLP	2-7-1	15	$CUB_{DAP\ Casca}$, $CUB_{DAP\ Lenho}$		Tangencial	Exponencial
Mg1	MLP	2-9-1	15	$CUB_{DAP\ Casca}$, $CUB_{DAP\ Lenho}$		Exponencial	Logística
Mg2	MLP	2-6-1	15	$CUB_{DAP\ Casca}$, $CUB_{DAP\ Lenho}$		Logística	Logística
S1	MLP	2-9-1	15	$CUB_{DAP\ Casca}$, $CUB_{DAP\ Lenho}$		Exponencial	Tangencial
S2	MLP	2-9-1	15	$CUB_{DAP\ Casca}$, $CUB_{DAP\ Lenho}$		Tangencial	Tangencial
GT1	MLP	8-7-1	90	$CUB_{DAP\ Casca}$, $CUB_{DAP\ Lenho}$		Nid	Exponencial
GT2	MLP	8-10-1	90	$CUB_{DAP\ Casca}$, $CUB_{DAP\ Lenho}$		Nid	Identidade
GC1	MLP	7-12-1	90	$CUB_{DAP\ Casca}$		Nid	Tangencial
GC2	MLP	7-12-1	90	$CUB_{DAP\ Casca}$		Nid	Logística

GT = Modelo 2 e GC = Modelo 3. Num são as entradas numéricas. n é o número de observações. CUB expresso em Kg de biomassa. Kg de nutriente⁻¹.

Tabela 4. Precisão das redes neurais artificiais (RNA)

RNA	Fases	RMSE%	Bias%	Erros Relativos (%)			Teste <i>t</i> <i>p</i>
				Máximo	Médio	Mínimo	
N1	Calibração	4,37	0,39	5,39	-0,24	-8,13	0,2572
	Teste	6,49	2,66	3,14	-2,42	-7,15	
	Validação	2,29	3,66	3,74	-3,5	-8,57	
N2	Calibração	2,88	-0,01	4,67	0,10	-6,46	0,086
	Teste	5,54	2,97	1,59	-2,93	-6,90	
	Validação	1,88	7,60	-2,84	-7,04	-9,22	
P1	Calibração	17,59	1,48	40,16	1,15	-18,00	0,5399
	Teste	25,86	-20,59	30,20	25,65	19,46	
	Validação	0,10	4,86	19,42	-2,39	-18,59	
P2	Calibração	17,98	2,72	39,07	-0,16	-19,16	0,5327
	Teste	26,86	-21,81	30,04	27,86	26,51	
	Validação	0,11	2,40	20,91	-0,17	-15,68	
K1	Calibração	9,45	-0,63	22,72	2,36	-12,91	0,0258
	Teste	26,54	-20,51	37,38	26,36	13,05	
	Validação	0,60	-17,68	41,34	22,66	9,58	
K2	Calibração	11,14	4,37	17,85	-3,06	-15,03	0,1492
	Teste	26,84	-20,67	37,90	26,62	12,67	
	Validação	0,59	-17,70	41,78	22,72	8,64	
Ca1	Calibração	8,75	-1,06	20,01	2,01	-15,67	0,4551
	Teste	28,64	-9,05	44,93	17,84	-15,99	
	Validação	1,76	-0,84	8,30	1,46	-11,65	
Ca2	Calibração	7,76	-0,61	14,20	1,46	-12,63	0,8221
	Teste	30,78	-7,88	44,09	16,91	-19,27	
	Validação	0,98	16,03	0,93	-13,40	-21,84	
Mg1	Calibração	11,56	2,57	10,91	-1,43	-19,38	0,6446
	Teste	16,83	-7,15	37,45	11,63	-4,25	
	Validação	0,10	8,16	18,42	-7,31	-30,42	
Mg2	Calibração	11,11	1,47	14,28	-0,37	-18,70	0,6163
	Teste	21,72	-1,27	38,23	6,83	-12,76	
	Validação	0,10	6,71	19,75	-6,04	-30,11	
S1	Calibração	6,69	-0,14	13,23	0,61	-11,23	0,8547
	Teste	5,56	2,38	2,95	-2,27	-5,89	
	Validação	0,25	-4,24	16,96	4,44	-20,12	
S2	Calibração	8,10	-0,73	11,46	1,42	-13,17	0,4833
	Teste	9,92	7,44	-2,77	-6,87	-8,94	
	Validação	0,32	3,67	16,04	-3,13	-15,75	
GT1	Calibração	25,42	1,00	54,07	4,10	-30,64	0,7801
	Teste	21,51	0,39	55,97	0,64	-39,49	
	Validação	24,71	-4,96	85,83	8,75	-33,56	
GT2	Calibração	24,32	-6,28	49,62	3,07	-28,43	0,2833
	Teste	24,78	0,03	48,57	6,25	-23,02	
	Validação	27,03	-6,76	52,91	10,87	-35,88	
GC1	Calibração	24,33	-0,09	53,90	2,25	-25,27	0,3041
	Teste	28,55	-6,49	34,47	3,87	-26,15	
	Validação	25,68	-5,91	53,26	10,14	-35,56	
GC2	Calibração	29,95	-5,27	57,29	2,54	-24,46	0,4073
	Teste	24,33	0,30	35,54	3,07	-25,91	
	Validação	25,96	-5,64	59,13	9,51	-35,53	

^{ns}($p > 0,05$) no teste *t* pareado. GT = Modelo 2; GC = Modelo 3.

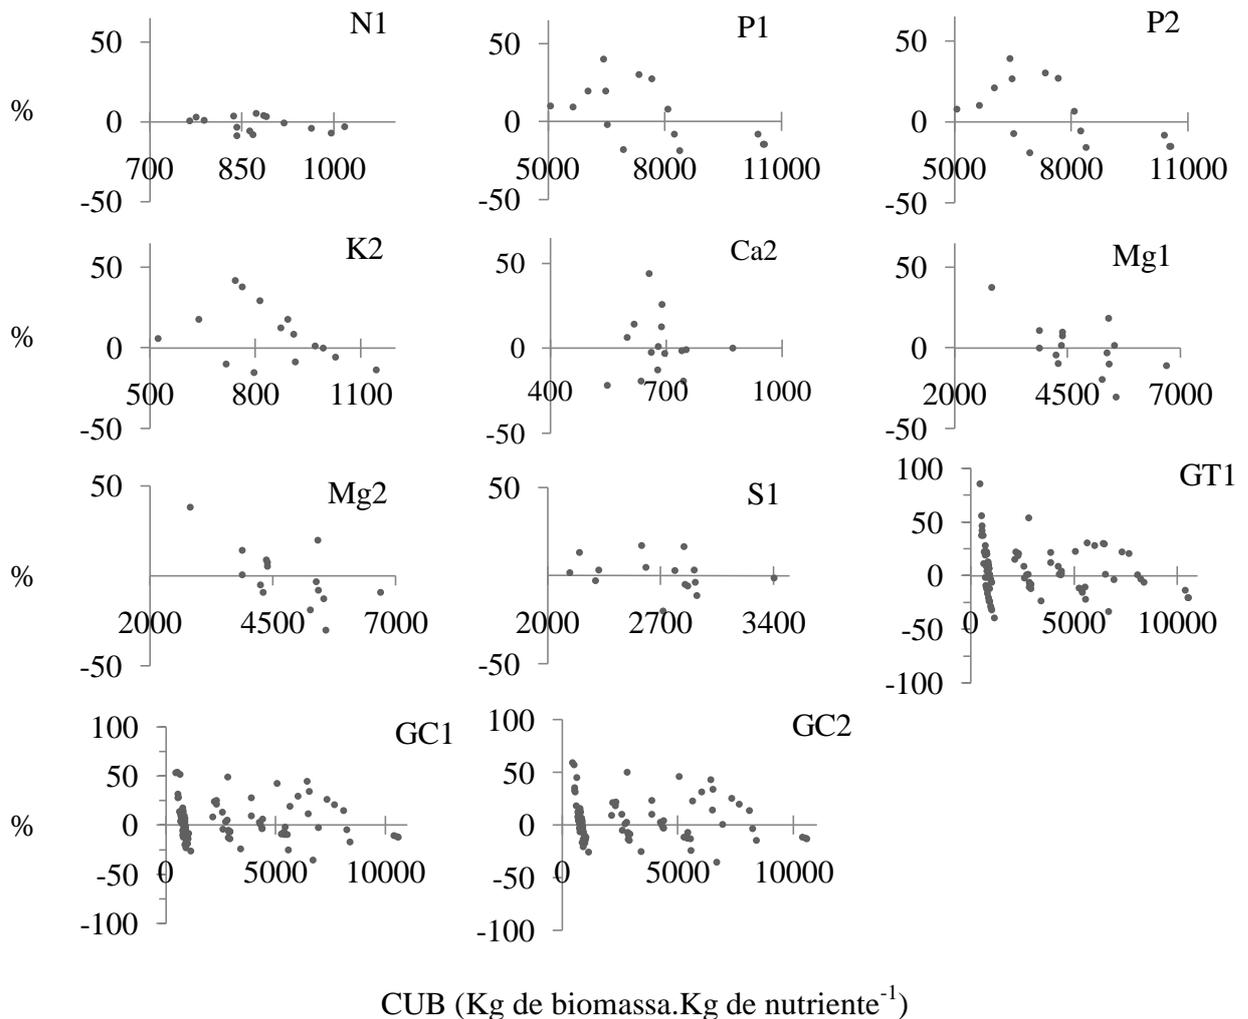


Figura 2. Distribuição dos resíduos percentuais (eixos y) em função dos CUB's no tronco (eixos x, kg de biomassa/kg de nutriente) pelas redes.

A superioridade da inteligência artificial por meio das RNA foi verificada em relação aos algoritmos de regressão (Tabelas 2 e 4; Figuras 1 e 2) para estimar o CUB_{Tronco} . Além de estimar de forma generalista simultaneamente para todos os macronutrientes o CUB_{Tronco} , baseando-se apenas na amostragem da casca na região do *DAP*.

Foi verificada a utilização de funções não lineares nas camadas intermediárias para a maioria das RNA (Tabela 3). Segundo Braga et al. (2007) esta tendência permite que a composição das funções nas camadas sucessivas tenha capacidade de resolver os problemas de maior ordem no espaço de entrada. Haja vista que a modelagem por RNA não visa o levantamento de parâmetros físicos do sistema, mas sim, prover um modelo que descreva o seu comportamento. A habilidade da rede em modelar qualquer processo não linear está relacionada ao seu sistema de processamento simples interligado por neurônios artificiais, que

aceitam *inputs* únicos ou múltiplos para produzir uma saída por uma função de transferência (Behera et al., 2011).

Embora as redes generalistas tenham apresentado um $RMSE_{\%}$ em torno de 25, o melhor treino e pior validação da rede GC1 (Tabela 3) não implicou em uma memorização excessiva dos dados de treinamento, pois não foram utilizados muitos neurônios na camada intermediária e aplicou-se uma normalização dos dados como heurística. Esta normalização é um recurso muito utilizado no processamento estatístico com RNA visando uma aproximação da solução ideal dos problemas minimizando os erros (Soares et al., 2011; Statsoft, 2007). É importante ressaltar que não existe um método generalizado para determinar valores ótimos para o número de camadas intermediárias ou de neurônios na mesma, pois estas ocorrem em função da inteligência esperada (Goyal e Goyal, 2011).

O desempenho das RNA generalistas foi mais conciso e consistente que as construídas por macronutriente, apresentando melhor distribuição das estatísticas de precisão entre as fases de treino, teste e validação (Tabela 4). Isto se deve, provavelmente, ao maior número de observações e representatividade no processamento das redes generalistas.

As redes GC foram construídas com apenas o $CUB_{DAP\ Casca}$ como variável mensurada em relação à GT1, que também necessita do $CUB_{DAP\ Lenho}$. Esta diferença possui grande significado prático, pois necessita-se amostrar apenas a casca na região do *DAP* e não casca e lenho. Consequentemente, o processo de amostragem em campo é muito mais rápido, menos oneroso e reduz à metade o custo analítico, além de ser menos laboriosa pela possibilidade de utilização de equipamentos mais simples e de fácil manuseio, como o facão para coletar a casca. Uma constante aferição nos valores do CUB_{Tronco} em condições de campo é necessária porque variações podem ocorrer para um mesmo material genético em função das condições edafoclimáticas (Santana et al., 2002). Desta forma, um modelo generalista como o obtido pelas redes reduz as atividades operacionais para obtenção do CUB_{Tronco} .

O CUB é a base da recomendação de fertilizantes e o método não destrutivo proposto pelo presente trabalho forneceu estimativas precisas. Apesar de ser mais complexa que a regressão a implementação das redes neurais como ferramenta demonstrou ser uma adequada opção para estimar o CUB. Esta é uma ferramenta que carece ser mais bem explorada nas áreas de pesquisa e nutrição florestal.

4. CONCLUSÃO

A modelagem por redes neurais artificiais utilizando-se apenas amostra da casca na região do *DAP* demonstrou ser adequada para a estimativa do coeficiente de utilização biológico do tronco.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- ALMEIDA, A. C.; SOARES, J. V.; LANSBERG, J. J.; REZENDE, G. D. Growth and water balance of *Eucalyptus grandis* hybrids plantations in Brazil during a rotation for pulp production. **Forest Ecology and Management**, p. 1-12, 2007.
- ALONGI, D. M.; CLOUGH, B. F.; ROBERTSON, A. I. Nutrient use efficiency in arid-zone forests of the mangroves *Rhizophora stylosa* and *Avicennia marina*. **Aquatic Botany**, v. 82, p. 121–131, 2005.
- BARROS, N. F.; NOVAIS, R. F.; CARMO, D. N.; NEVES, J. C. L. Classificação nutricional de sítios florestais - Descrição de uma metodologia. **Revista Árvore**, v. 10, n. 2, p. 112-120, 1986.
- BARROS, N. F.; NOVAIS, R. F.; TEIXEIRA, J. L.; FERNANDES FILHO, E; I. Nutricalc 2.0 – Sistema para cálculo del balance nutricional y recomendación de fertilizantes para el cultivo de eucalipto. **Bosque**, v. 16, n. 1, p. 129-131, 1995.
- BEHERA, S. K.; RENE, E. R.; PARK, H. S. Neural network modeling of sorption of pharmaceuticals in engineered floodplain filtration system. **Expert Systems with Applications**, v. 39, p. 1-9, 2011.
- BINOTI, M. L. M. S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 2010. 54f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa-Mg, 2010.
- BRAGA, A. P.; CARVALHO, A. P.; LUDERMIR, T. B. **Redes neurais artificiais: Teoria e aplicações**. 2 ed. Rio de Janeiro: LTC, 2007. 226 p.
- BULLINÁRIA, J. A. **Introduction to Neural Computation**. Notas de aula. 2011. Disponível em: < <http://www.cs.bham.ac.uk/~jxb/inc.html>>. Acesso em: 8 de nov. 2011.
- CHAPIN, F. S. The mineral nutrition of wild plants. **Annual Review of ecology and systematic**, v.11, p. 233-260, 1980.

COELHO, L. S.; SILVA, W. V.; PROTIL, R. M. Previsão não-linear dos preços de troncos de eucalipto baseada em uma abordagem neuroevolutiva. **Gestão & Produção**, v. 14, n. 1, p. 139-154, 2007.

COSTA, A. M.; CURI, N.; ARAÚJO, E. F.; MARQUES, J. J.; MENEZES, M. D. Avaliação do risco de anoxia para o cultivo do eucalipto no Rio Grande do Sul utilizando-se levantamento de solos. **Scientia Forestalis**, v. 37, n. 84, p. 367-375, 2009.

GORGENS, E. B.; LEITE, H. G.; SANTOS, H. N.; GLERIANI, J. M. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, v. 33, n. 6, p. 1141-1147, 2009.

GOYAL, S.; GOYAL, G. K. Cascade and feedforward backpropagation artificial neural network models for prediction of sensory quality of instant coffee flavoured sterilized drink. **Canadian Journal on Artificial Intelligence, Machine Learning and Pattern Recognition**, v. 2, n. 6, 2011.

INMET – Instituto Nacional de Meteorologia. Disponível em: <<http://www.inmet.gov.br>>. Acesso em 16 de out. 2010.

MABVURIRA, D.; MIINA, J. Individual-tree growth and mortality models for *Eucalyptus grandis* (Hill) Maiden plantations in Zimbabwe. **Forest Ecology and Management**, v. 161, p. 231-245, 2002.

MENDES, S. C.; MOLICA, S. G.; FERREIRA, R. L. C.; CÉSPEDES, H. G. Absorção e distribuição de nutrientes em plantios comerciais de bambu (*Bambusa vulgaris*) no nordeste do Brasil. **Revista Árvore**, Viçosa-MG, v. 34, n. 6, p. 991-999, 2010.

PULROLNIK, K.; BARROS, N. F.; SILVA, I. R.; NOVAIS, R. F.; BRANDANI, C. B. Estoques de carbono e nitrogênio em frações lábeis e estáveis da matéria orgânica de solos sob eucalipto, pastagem e cerrado no Vale do Jequitinhonha-MG. **Revista Brasileira de Ciência do Solo**, v. 33, p. 1125-1136, 2009.

SAIDELES, F. L. F.; CALDEIRA, V. W.; SCHUMACHER, M. V.; BALBINOT, R.; SCHIRMER, W. N. Determinação do ponto de amostragem para a quantificação de macronutrientes em *Acacia mearnsii* de Wild. **Floresta**, v. 40, n. 1, p. 49-62, 2010.

SANTANA, R. C.; BARROS, N. F.; NEVES, J. C. L. Eficiência de utilização de nutrientes e sustentabilidade da produção em procedências de *Eucalyptus grandis* e *Eucalyptus saligna* em sítios florestais do estado de São Paulo. **Revista Árvore**, Viçosa-MG, v.26, n.4, p.447-457, 2002.

SANTANA, R. C.; BARROS, N. F.; NOVAIS, R. F.; LEITE, H. G.; COMERFORD, N. B. Alocação de nutrientes em plantios de eucalipto no Brasil. **Revista Brasileira de Ciência do Solo**, v. 32, p. 2723-2733, 2008.

SILVA, K. S.; CECÍLIO, R. A.; Uso de redes neurais artificiais para a estimativa das temperaturas do ar médias, máximas e mínimas, mensais e anuais no estado do Espírito Santo. **Caminhos de Geografia** - revista *online*, v. 11, n. 34, p. 84-92, 2010.

SOARES, F. A. A. M. N.; FLÔRES, E. F.; CABACINHA, C. D.; CARRIJO, G. A.; VEIGA, A. C. P. Recursive diameter prediction and volume calculation of eucalyptus trees using Multilayer Perceptron Networks. **Computers and Electronics in Agriculture**, v. 78, p. 19–27, 2011.

STATSOFT, INC. Statistica (data analysis software system), version 7. Disponível em: <<http://www.statsoft.com>>, 2007.

CONCLUSÕES GERAIS

A modelagem por redes neurais artificiais demonstrou-se adequada para estimar a produção de biomassa de tronco em função da idade sob diferentes espaçamentos, utilizando o *DAP* e perímetro foliar como variáveis preditoras.

Não houve grande variação da eficiência de uso dos nutrientes entre os espaçamentos, principalmente para o tronco.

A rede neural artificial foi eficiente em estimar a eficiência de uso dos nutrientes.

A modelagem por redes neurais artificiais utilizando-se apenas amostra da casca na região do *DAP* demonstrou ser adequada para a estimativa do coeficiente de utilização biológico do tronco.

APÊNDICE

Tabela 1A. Equações para estimar o volume sem casca por espaçamento

Espaçamentos	Equações	n	\bar{R}^2
3,0 x 0,5 m	$LnVSC = -9,966^* + 2,278^*LnDAP + 0,702^*LnHt$	50	0,995
3,0 x 1,0 m	$LnVSC = -10,103^* + 1,958^*LnDAP + 0,987^*LnHt$	50	0,991
3,0 x 1,5 m	$LnVSC = -10,326^* + 1,944^*LnDAP + 1,069^*LnHt$	50	0,994
3,0 x 2,0 m	$LnVSC = -10,569^* + 1,745^*LnDAP + 1,309^*LnHt$	50	0,989
3,0 x 3,0 m	$LnVSC = -10,787^* + 1,644^*LnDAP + 1,454^*LnHt$	50	0,983

*significativo a 5,0 % de probabilidade; $DAP_{(cm)}$; Ht (altura total, m); VSC = Volume sem casca_(m3); \bar{R}^2 = coeficiente de determinação corrigido; n = número de observações.

Tabela 2A. Equações para estimar o conteúdo de nutrientes de casca e lenho

	Equações	n	\bar{R}^2
----- Casca -----			
N	$LnN = -6,818^{**} + 0,087^{**}DAP + 0,073^{**}Ht$	15	0,997
P	$LnP = -19,323^{**} - 0,160^{*}DAP + 4,708^{**}LnHt$	15	0,998
K	$LnK = -14,407^{**} + 3,221^{**}LnHt$	15	0,998
Ca	$LnCa = -5,054^{**} + 0,007^{**}DAP Ht$	15	0,988
Mg	$LnMg = -8,740^{**} + 0,147^{**}Ht$	15	0,997
S	$LnS = -12,688^{**} + 2,654^{**}LnDAP$	15	0,999
----- Lenho -----			
N	$LnN = -11,194^{**} + 3,295^{**}LnDAP$	15	0,982
P	$LnP = -11,470^{**} + 2,567^{**}LnDAP$	15	0,998
K	$LnK = -9,946^{**} + 2,845^{**}LnDAP$	15	0,992
Ca	$LnCa = -5,664^{**} + 0,190^{**}DAP$	15	0,966
Mg	$LnMg = -11,735^{**} + 2,713^{**}LnDAP$	15	0,972
S	$LnS = -12,067^{**} + 3,902^{**}LnDAP - 0,061^{*}Ht$	15	0,999

** significativo a 1,0 %, * significativo a 5,0 % de probabilidade; *DAP* (cm); *Ht* (m); Conteúdo de nutrientes em kg por componente e indivíduo; biomassa em kg e \bar{R}^2 = coeficiente de determinação corrigido.