

MULTI-LAYER PERCEPTRON NA PREDIÇÃO RECURSIVA DE DIÂMETROS DE CLONE DE EUCALIPTO

Fabrizzio A. A. M. N. Soares¹, Edna L. Flores², Christian D. Cabacinha³, Gilberto A. Carrijo⁴, Antônio C. P. Veiga⁵, Milena B. P. Carneiro⁶

1 - Universidade Federal de Goiás, Campus Jataí, Jataí – GO, fabrizzio.soares@gmail.com

2 – Universidade de Minas Gerais, Instituto de Ciências Agrárias, Montes Claros – MG, ccabacinha@yahoo.com.br

3 – Universidade Federal de Uberlândia, Faculdade de Engenharia Elétrica, Uberlândia – MG, edna@ufu.br

4 - Universidade Federal de Uberlândia, Faculdade de Engenharia Elétrica, Uberlândia – MG, gilberto@ufu.br

5 - Universidade Federal de Uberlândia, Faculdade de Engenharia Elétrica, Uberlândia – MG, acpveiga@ufu.br

6 - Universidade Federal de Uberlândia, Faculdade de Engenharia Elétrica, Uberlândia – MG, milenabueno@yahoo.com

Resumo - Um dos grandes desafios na área florestal é a predição do volume dos povoamentos de forma rápida e precisa sem a necessidade de abater árvores. A proposta deste trabalho é um modelo que utiliza a rede neural artificial Perceptron de Múltiplas Camadas (MLP) na predição de diâmetros de árvores. Este modelo necessita de 3 medidas de diâmetros da base da árvore e de forma recursiva prevê as demais medidas de diâmetros. A performance do modelo proposto foi satisfatória quando comparado com os volumes obtidos a partir da cubagem rigorosa.

Palavras-Chave – Estimativa de diâmetro, Inventário Florestal, Perceptron de Múltiplas Camadas, Predição Recursiva.

RECURSIVE DIAMETER PREDICTION OF EUCALYPTUS TREES USING MULTILAYER PERCEPTRON NETWORKS

Abstract - A major challenge in forest management is the ability to quickly and accurately predict bole volume of standing trees. This study presents a model that uses Multilayer Perceptron (MLP) artificial neural networks for predicting tree volume. The model requires three diameter measures at the base of the tree, and recursively predicts other diameter measures. The performance of the proposed model was satisfactory when compared with data obtained from tree scaling.

Keywords – Estimating diameter, Forest Inventory, Multiple Layer Perceptron, Recursive Prediction.

I. INTRODUÇÃO

Aproximadamente 62%, ou seja, em torno de 3 milhões de hectares das florestas plantadas no Brasil são do gênero Eucalyptus. O grande investimento de indústrias de papel e celulose, aliados aos esforços de instituições de pesquisas e universidades tornaram esse país um dos maiores produtores de madeira de eucalipto do mundo.

¹Nota de rodapé na página inicial será utilizada apenas pelo professor avaliador para indicar o andamento do processo de revisão. Não suprima esta nota de rodapé quando editar seu artigo.

O eucalipto é uma espécie florestal de rápido crescimento, menor custo, e produz muito mais madeira que outras espécies. A produtividade média de madeira no Brasil é de 45-50m³ ha⁻¹ ano⁻¹. No Chile, Estados Unidos, Canadá e Finlândia, esse número é de 20, 10, 7 e 4m³ ha⁻¹ ano⁻¹, respectivamente [1].

O volume de madeira plantado é uma informação essencial no direcionamento racional e sustentável dos recursos disponíveis nas florestas. Assim, é muito importante quantificá-lo da forma mais precisa possível. O método mais tradicional utilizado nas empresas brasileiras são as equações volumétricas. Estas equações são ajustadas com amostras de cubagem rigorosa durante a realização do inventário florestal.

Nas equações volumétricas são feitas suposições geométricas sobre as árvores. Estas suposições necessitam de diversas medidas de diâmetros ao longo do fuste (tronco) para a construção dos modelos que representam o estrato (sub-área) do povoamento. No entanto, durante a cubagem, as árvores amostradas são abatidas. Como este processo é repetido várias vezes até completar todos os estratos da população, esta atividade torna-se bastante demorada e onerosa. Com isto, muitas vezes as empresas florestais negligenciam a cubagem prejudicando as predições realizadas com as equações volumétricas [2].

A partir dos anos 90, muitos pesquisadores tem utilizado as redes neurais artificiais (RNAs) em aproximação de funções não-lineares. As RNAs não exigem qualquer suposição geométrica sobre a função a ser aproximada. Elas têm sido aplicadas em diversas áreas como finanças, previsão de séries temporais, classificação de padrões, entre outras.

As redes neurais têm sido usadas na modelagem florestal para estimar diversos parâmetros das árvores tais como diâmetro, altura, volume, e outros.

[3] utilizou as RNAs para estimar os diâmetros do fuste baseado no diâmetro na altura do peito e no crescimento anual dos diâmetros.

[4] previu os diâmetros das árvores baseados nos diâmetros na altura do peito (DAP) e nas alturas totais da árvore utilizando redes neurais artificiais.

Em [5] as redes neurais foram usadas para estimar os diâmetros das árvores. Nessas RNAs foram utilizadas 22 entradas tais como altitude, aspecto, área basal, dentre outros.

Inspirado na forte autocorrelação entre os 3 diâmetros vizinhos usados como entrada e o próximo diâmetro a ser previsto. A proposta deste trabalho é utilizar a rede neural

artificial Perceptron de Múltiplas Camadas (MLP) na predição de diâmetros de árvores. Este modelo usa como entrada 3 medidas de diâmetro na base da árvore e de forma recursiva prevê as demais medidas de diâmetros ao longo do fuste.

Este artigo está organizado como segue. Na seção 2 o modelo de predição recursiva e a arquitetura da MLP são explicados, onde os detalhes mais significativos são dados durante o treinamento. Os métodos de validação também são explicados. Na seção 3 são apresentados os detalhes sobre o desempenho do modelo proposto e dos métodos tradicionais. Finalmente, na seção 4 as conclusões são apresentadas.

II. MÉTODOS DE PREDIÇÃO E REDES NEURAIS

A. Predição

A predição de séries é utilizada comumente em séries temporais. Ela pode ser considerada como um problema de modelagem. Para a predição, um modelo é construído entre as entradas e as saídas. Este modelo é usado para prever os próximos valores baseados nos valores prévios. A predição direta e a recursiva são alguns dos métodos aplicados na predição de longa duração [7].

1) Predição Direta - Para prever os valores de uma série são construídos $M + 1$ modelos diferentes, conforme a Equação (1).

$$\hat{d}_{i+m} = f_m(d_{i-1}, d_{i-2}, \dots, d_{i-n}), \quad (1)$$

onde $m = 0, 1, \dots, M$; M é o horizonte máximo da predição e n é o tamanho do regressor.

As variáveis de entrada do lado direito da Equação (1) definem o regressor.

2) Predição Recursiva - A predição recursiva pode ser construída primeiro fazendo a predição de um passo adiante, conforme a Equação (2).

$$\hat{d}_i = f(d_{i-1}, d_{i-2}, \dots, d_{i-n}), \quad (2)$$

Para prever o próximo valor da série, utiliza-se também a Equação (2), porém o primeiro valor dessa equação é o resultado dela no passo anterior, como mostrado na Equação (3).

$$\hat{d}_{i+1} = f(\hat{d}_i, d_{i-1}, d_{i-2}, \dots, d_{i-n+1}). \quad (3)$$

B. Rede Neural artificial Perceptron de Multiplas camadas (MLP)

A rede neural Perceptron de Multiplas Camadas (MLP) é composta de uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. O sinal de entrada propaga-se para frente pela rede, camada por camada [7]. A Figura 1 mostra a MLP utilizada neste trabalho.

O cálculo do número de neurônios da camada oculta da rede MLP é obtido pela Equação (4) [8].

$$N = \text{integer} \left(\frac{n}{2} + \sqrt{R} \right), \quad (4)$$

onde n é o número de neurônios de entrada e R é o tamanho do conjunto de dados.

Diversas funções de ativação que podem ser utilizadas na rede MLP [7]. A função de ativação utilizada neste trabalho nos neurônios das camadas oculta e de saída foi a tangente hiperbólica, também chamada de tan-sigmóide ou tansig, calculada conforme a Equação (5).

$$\varphi(a) = \tanh(a) = \frac{2}{(1 + \exp(-2a))} - 1 \quad (5)$$




Fig. 1. Arquitetura da MLP de 3 camadas.

Existe uma variedade de algoritmos para treinamento da MLP. Estes algoritmos são o gradiente descendente, o gradiente descendente com momentum, o gradiente conjugado, o quasi-Newton, o Levenberg-Marquardt, e outros.

A técnica de Levenberg-Marquardt é mais eficiente do que a técnica do gradiente descendente convencional [9]. O gradiente descendente é um algoritmo de maior descida e envolve movimentos de pequenos passos abaixo do gradiente local do campo escalar. Uma desvantagem deste método é a possibilidade do gradiente descendente encontrar um mínimo local antes que o mínimo global seja atingido. O algoritmo Levenberg-Marquardt é um aperfeiçoamento do método Gauss-Newton, que é uma variante do método de Newton [10][11]. O método de Newton usa a informação da derivada parcial de segunda ordem do índice de desempenho utilizado para corrigir os pesos. Isso permite que além da informação do gradiente, seja usada informação sobre a curvatura da superfície do erro.

C. Cálculo dos Erros dos Diâmetros Preditos com a MLP

Com a finalidade de verificar o comportamento da MLP na estimação de todos os diâmetros de cada árvore foram utilizadas a Raiz Quadrada do Erro Médio ($rmse_{\%}$) e a correlação linear ($r_{Y\hat{Y}\%}$), conforme as Equações (6) e (7), respectivamente.

$$rmse_{\%} = \frac{1}{Y} \left(\left(\sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \right) \frac{1}{n} \right)^{1/2} \times 100 \quad (6)$$

$$r_{Y\hat{Y}\%} = \frac{n \left(\sum_{i=1}^n \hat{Y}_i Y_i \right) - \left(\sum_{i=1}^n \hat{Y}_i \right) \left(\sum_{i=1}^n Y_i \right)}{\left(n \left(\sum_{i=1}^n Y_i^2 \right) - \left(\sum_{i=1}^n Y_i \right)^2 \right)^{1/2}} \quad (7)$$

onde \bar{Y} é a média dos diâmetros, \hat{Y}_i e Y_i são os diâmetros preditos e medidos, respectivamente, e n é o número de medidas de diâmetros entre as medidas de entrada e a altura total.

III. RESULTADOS E DISCUSSÃO

Neste trabalho foram realizados vários testes para encontrar a estrutura da MLP que mais se adequava à predição de diâmetro das árvores. Para encontrar o número de neurônios na camada oculta utilizou-se a Equação (4). Embora o cálculo com esta equação sugira uma quantidade de neurônios grande, não ocorreu melhoria significativa nos valores de $rmse\%$ e $r_{Y\hat{Y}\%}$ quando foi utilizado um número maior do que 20 neurônios nessa camada. Portanto, a estrutura da MLP que mais se adequou foi a mostrada na Figura (1). Esta estrutura possui uma camada de entrada com três variáveis, que representam três medidas de diâmetros, uma camada oculta com $m = 20$ neurônios, e uma camada de saída com um neurônio, que resulta em um valor de diâmetro estimado.

A. Dados

Os dados utilizados neste estudo foram levantados em um plantio localizado no município de Aracruz, na região metropolitana do estado do Espírito Santo, no Brasil. Foram usados 615 árvores, do gênero *Eucalyptus*, obtidas de um mesmo material genético clonal. Todas elas com a mesma idade, 6 anos e seis meses, plantadas com espaçamento 3×3 m, distribuídas em 16 parcelas circulares de 360 m². Estas árvores foram abatidas e cubadas rigorosamente pelo método Smalian [12]. Durante a cubagem foram medidos, com Suta, os diâmetros nas alturas 0,10; 0,30; 0,50; 0,70; 0,90, 1,10; 1,30; 2,00 m em relação ao solo, no restante do tronco em intervalos de 1 em 1 m e o diâmetro no topo da árvore é considerado igual a zero cm. Os diâmetros nas alturas $h_{0,3}$ e $h_{1,3}$ são conhecidos como diâmetro do toco e diâmetro na altura do peito (DAP), respectivamente.

Diversas características das árvores variam de acordo com o DAP. Devido a isto, vários trabalhos têm separado as árvores em classes diamétricas baseadas no DAP em amplitudes de 4 e 5 cm [13]. Neste trabalho, as árvores foram separadas de acordo com a medida do DAP em 5 classes em intervalos de 3 cm e criou-se uma MLP para treino e predição de cada uma dessas classes. Apenas a classe 5 foi ampliada para inserir uma única árvore que estava isolada.

O modelo de MLP proposto neste trabalho baseou-se na relação entre os 3 diâmetros vizinhos usados como entrada e o próximo diâmetro que é previsto na saída da rede. Com a finalidade de verificar a relação da medida de um diâmetro com seus diâmetros vizinhos, foi calculado o coeficiente de autocorrelação utilizando-se a Equação (7). O cálculo da autocorrelação foi feito para cada árvore com

deslocamentos de 1 a 3. A Tabela I mostra o menor e o maior coeficientes de autocorrelação para 1 deslocamento em cada classe.

TABELA I
Autocorrelação por classe

Classe	N	Autocorrelação(d,%)		
		Min	Max	
1	14	63	84	
2	106	77	87	
3	302	78	89	
4	178	83	90	
5	15	82	90	

Os resultados obtidos nos testes de autocorrelação realizados para 1 deslocamento apresentaram valores bastante altos. Pode-se verificar na Tabela I que a menor e a maior autocorrelação para 1 intervalo foram de 0,63 e 0,90, respectivamente. Enquanto no teste para 3 intervalos a menor e a maior autocorrelação foram de 0,55 e 0,81. Assim os testes comprovaram que existe um forte relacionamento entre os 3 diâmetros vizinhos e o próximo diâmetro a ser previsto.

Para uma maior confiabilidade e rapidez no treinamento das MLPs normalizou-se os dados de diâmetros das árvores no intervalo de [-1,1], usando a Equação (8). Neste intervalo o -1 indica diâmetros iguais a 0, 1 o maior diâmetro e entre esses valores os demais diâmetros [14]. A normalização foi feita em todas as árvores independente de sua classe.

$$X_{NORM} = (b-a) \cdot \left(\frac{X - \min(X)}{\max(X) - \min(X)} \right) + a, \quad (8)$$

onde X_{NORM} é o valor do diâmetro normalizado, X é o diâmetro da árvore, $\min(X)$ é o menor diâmetro das árvores, $\max(X)$ é o maior diâmetro das árvores, $a = -1$ e $b = 1$ são os intervalos de normalização.

Após a predição dos diâmetros das árvores pelas MLPs, estes diâmetros foram denormalizados usando os valores de $\min(X)$ e $\max(X)$ utilizados na normalização.

O algoritmo de treino utilizado nas MLPs foi o Levenberg-Marquardt [11] com 1.000 épocas. Todos os treinos das MLPs foram realizados com pesos iniciais aleatórios e não foram utilizados parâmetros adaptativos de taxa de aprendizado e momentum.

Para evitar o *overfit*, neste trabalho foi utilizado uma adaptação do método *early stopping* [15]. Nesta adaptação a heurística adotada foi estabelecer o erro médio quadrático (MSE) em 1×10^{-10} e treinar as MLPs até que por 5 épocas seguidas o MSE não apresentasse redução significativa ou aumentasse. Nos testes realizados, as MLPs convergiram abaixo de 150 épocas. A Tabela II mostra os valores de MSE e o número médio de épocas para convergência em cada classe de árvore.

TABELA II
Amostras de Treino

Classe	Total		Amostras		Treino	
	Árvores	Conj.	Árvores	Conj.	Épocas	MSE
1	14	231	10	155	35	$3,0 \times 10^{-4}$
2	106	2405	11	239	45	$3,0 \times 10^{-4}$

3	302	8025	31	792	120	3,5x10 ⁻⁴
4	178	5105	18	498	110	3,5x10 ⁻⁴
5	15	462	10	298	130	5,0x10 ⁻⁴
Total	615	16228	80	1982	-	-

Para o treino das MLPs, em cada classe foram selecionadas aleatoriamente 10% das árvores ou no mínimo 10 árvores para a geração dos conjuntos de amostras de entrada e saída. Para cada uma destas árvores foram geradas as amostras de entradas $[d_{i-2}, d_{i-1}, d_i]$ e a saída $[d_{i+1}]$. Por exemplo, no treinamento da rede, o par de entrada e saída foi $[d_{0,3}, d_{0,7}, d_{1,3}]$ e $[d_{2,0}]$, onde $d_{0,3}, d_{0,7}, d_{1,3}, d_{2,0}$ representam a distância do solo até as medidas 0,3, 0,7, 1,3 e 2,0 metros. O próximo par de entrada e saída foi $[d_{0,7}, d_{1,3}, d_{2,0}]$ e $[d_{3,0}]$, onde $d_{3,0}$ representa a distância do solo até a medida 3,0 metros, e assim sucessivamente.

Na etapa de teste das MLPs são utilizadas apenas as medidas iniciais de diâmetro $d_{0,3}, d_{0,7}$ e $d_{1,3}$ para prever as demais medidas de diâmetros de cada árvore. Esta etapa é realizada para cada árvore individualmente, conforme o procedimento de predição recursiva descrito na Equação (3). Portanto, estas medidas iniciais são utilizadas para prever o diâmetro $d_{2,0}$. Em seguida, as medidas $d_{0,7}, d_{1,3}$ e a $d_{2,0}$ estimada são utilizadas para prever a medida $d_{3,0}$, e assim sucessivamente. Este procedimento está descrito na Tabela III e no Algoritmo I ilustra as definições utilizadas nesse algoritmo.

TABELA III

Definição formal do algoritmo de predição

X	O vetor de entradas da MLP
X ₁	A entrada 1 da MLP
X ₂	A entrada 2 da MLP
X ₃	A entrada 3 da MLP
i	A altura que está sendo predita
d _{0,3}	O diâmetro na altura 0,3 (Diâmetro do Toco)
d _{0,7}	O diâmetro na altura 0,7
d _{1,3}	O diâmetro na altura 1,3 (dbh)
D	O vetor de diâmetros preditos até a altura total. Na altura total o diâmetro é adotado como zero
D _i	O Diâmetro na altura i
H _t	A Altura total da árvore predita

Algoritmo I
Algoritmo de Predição

FUNCAO PredictTree(d_{0,3}, d_{0,7}, d_{1,3}, H_t)

```

X ← [d0,3, d0,7, d1,3]
D ← []
i ← 2,0
ENQUANTO i < Ht
  Di ← Net.Predict(X)
  X1 ← X2
  X2 ← X3
  X3 ← Di
  i ← i + 1,0

```

FIM ENQUANTO
RETURNE D

FIM FUNCAO

B. Predição de Diâmetros

Devido à grande quantidade de árvores previstas, a Tabela IV mostra de forma resumida os valores de rmse% e Correlação (r_{YŶ}%) dos testes realizados para predição dos diâmetros das árvores.

TABELA IV
Erros de predição de diâmetros por classe - RMSE% (Menor, Maior, Médio e Desvio Padrão) e Correlação (Menor, Maior)

Classe	Arvs.	RMSE%				Correlação%	
		Min	Max	Média	Desvio	Min	Max
1	4	3,0485	9,9825	6,2052	3,4018	96,77	99,77
2	95	1,8253	22,9360	7,3111	4,2031	98,35	99,99
3	271	1,6863	21,3653	6,6817	3,6985	97,18	99,92
4	160	1,6740	22,8324	7,4058	4,4258	98,83	99,93
5	5	2,0645	6,2103	4,3476	1,6525	99,59	99,91

Pode-se observar na Tabela IV que nas classes 1 e 5, onde a quantidade de árvores é muito pequena, o maior valor de RMSE% é menor do que 10%. E que nas classes 2, 3 e 4, onde a quantidade de árvores é bem maior do que nas classes 1 e 5, o maior valor de RMSE% está em torno de 22%. Embora este último valor seja grande, a média dos RMSE% (erros) das classes 2,3 e 4 ficou em torno de 7%, mostrando que os diâmetros preditos pelas MLPs estão bastante próximos dos diâmetros reais medidos nas árvores. Essa tabela também ilustra o menor e o maior coeficientes de correlação linear entre os diâmetros preditos e medidos. Praticamente todos esses coeficientes estão no intervalo de 0,96 a 0,99. Assim existe uma fortíssima correlação linear entre os diâmetros reais medidos e os preditos pelas MLPs.

As Figuras 2 e 3 mostram com linhas contínuas e pontilhadas os valores de diâmetros reais e estimados pelas MLPs, respectivamente. E a Figura 4 ilustra o histograma dos RMSE% calculados para cada árvore da classe 3.

A Figura 2 mostra o menor RMSE% para a classe 3. Pode-se observar nessa figura que os valores dos diâmetros reais e estimados pelas MLPs são bastante coincidentes uns com os outros. Verifica-se também que as MLPs possuem uma alta aproximação para os casos em que as árvores apresentam um perfil linear e mesmo quando o perfil das árvores é não linear as MLPs acompanharam satisfatoriamente as variações bruscas de diâmetros.




Fig. 2. Arquitetura da MLP de 3 camadas.

O maior RMSE% para a classe 3 é mostrado na Figura 3. Pode-se verificar nessa figura que as MLPs subestimaram os valores reais dos diâmetros das árvores para a classe.




Fig. 3. Arquietura da MLP de 3 camadas.

A Figura 4 mostra o histograma de RMSE% para a classe 3. Pode-se verificar nessa figura que a maior parte dos valores de RMSE% estão abaixo de 10% que é um valor bastante satisfatório. Como a quantidade de árvores de teste nas classes 1 e 5 é muito pequena não existe um acúmulo de RMSE% em torno da média, porém todos RMSE% estão abaixo de 10% e 6,3% nas classes 1 e 5, respectivamente, que também são valores bastante satisfatórios.

Embora as Figuras 2 e 3 ilustrem os diâmetros reais e preditos de algumas árvores, o comportamento de todas as árvores utilizadas para teste mostraram que as MLPs tiveram dificuldade para prever os diâmetros mais próximos do topo das árvores. Isso já era esperado pois o modelo proposto neste trabalho realiza previsões recursivas e o erro em um determinado diâmetro será repassado para predição do próximo diâmetro. Portanto, quanto mais previsões recursivas forem realizadas maior o valor da diferença entre os diâmetros real e o predito pelas MLPs. No entanto, essa diferença influencia muito pouco no cálculo do volume de cada árvore.




Fig. 4. Arquietura da MLP de 3 camadas.

IV. CONCLUSÕES

Para prever os diâmetros de árvores pelas MLPs é necessário para cada árvore apenas 3 medidas de diâmetros reais na sua base. No treino das MLPs são necessários dados de cubagem rigorosa de aproximadamente 10% das árvores da população, o tempo total de treinamento para os MSEs estabelecidos foi em média 30 segundos e o tempo total de predição foi de 15 minutos. Enquanto em um inventário tradicional para o ajuste de equações volumétricas é

necessário abater e cubar rigorosamente muitas árvores da população e o tempo gasto para a realização desta prática é muito superior ao tempo do modelo com MLPs.

Os resultados obtidos com as redes neurais foram bastante satisfatórios na predição de diâmetros de árvores. Assim, pode-se recomendar seu uso na automação de processos de inventário florestal, pois elas reduzem significativamente o custo e o tempo da realização do inventário. Além disso, esta abordagem está menos susceptível a erros humanos durante o processo de inventário florestal.

REFERÊNCIAS BIBLIOGRÁFICAS (EXEMPLOS)

- [1] Votorantim Celulose e Papel – VCP, “Sustainable growth with value creation and solid returns”, VCP, VCP, 28p, jan-dez 2004.
- [2] V.C.L. Andrade, N. Calegario, and J.R.S. Scolforo, “Análise de algumas alternativas para obter o coeficiente angular da reta no método da altura relativa”, *Ciência Florestal* 16(3), volume 16, 303–337, 2006.
- [3] B.T. Guan, and G. Gertner, “Modeling red pine tree survival with an artificial neural network”, *Forest Science* 37(5), volume 37, 1429–1440, November 1991.
- [4] M.J. Diamantopoulou, “Predicting fir trees stem diameters using Artificial Neural Network models”, *Southern African Forestry Journal* 205(1), volume 205, 39–44, November 2005.
- [5] S. Kaloudis, T. Glezakos, K.P. Ferentinos, T.A. Tsiligiridis, and C.P. Yialouris, “Feedforward Neural Network Modeling of Fir Taper in Natural Forests of Greece”, *International Conference on Sustainable Management and Development of Mountainous and Island Areas*, October 2006.
- [6] Y. Ji, J. Hao, N. Reyhani, and A. Lendasse, “Direct and Recursive Prediction of Time Series Using Mutual Information Selection”, *IWANN 2005, Lecture Notes in Computer Science*, volume 3512, Springer Verlag, 1010–1017, 2005.
- [7] S. Haykin, “Neural Networks - A comprehensive Foundation”, 2nd edition, Prentice Hall: Upper Saddle River, 1998.
- [8] C.D. Doan, and S. Liang, “Generalization for multilayer neural network bayesian regularization or early stopping”, *APHW2004 Conference*, 2004.
- [9] M.T. Hagan, and M.B. Menhaj, “Training feed forward networks with the Marquardt algorithm”, *IEEE Transactions on Neural Networks*, volume 6, IEEE, 861–867, 1994.
- [10] K. Levenberg, “A method for the solution of certain non-linear problems in least squares”, *Quarterly Journal of Applied Mathematics* II(2), volume II, 164–168, 1944.
- [11] D. Marquardt, “An algorithm for least squares estimation of non-linear parameters”, *Journal of the society of Industrial and Applied Mathematics*, 431–441, 1963.
- [12] C.D. Cabacinha, “Um método para a realização do inventário florestal suprimindo a cubagem rigorosa”, *Universidade Federal de Lavras*, 2003.

- [13] L.M. Pires, e N. Calegario, “Ajuste de modelos estocásticos lineares e não-lineares para a descrição do perfil longitudinal de árvores”, *Revista Árvore* 31(5), volume 31, 845–852, 2007.
- [14] C. Zanchettin, e T.B. Ludermir, “Sistemas neurais híbridos para reconhecimento de padrões em narizes artificiais”, *SBA Controle & Automação* 16(2), volume 16, 2005.
- [15] A. Lodwich, Y. Rangoni, e T. Breuel, “Evaluation of robustness and performance of early stopping rules with multi layer perceptrons”, 2009 international joint conference on Neural Networks, 2009.