



AVALIAÇÃO DA PREVISIBILIDADE DOS PREÇOS DA MADEIRA DE EUCALIPTO UTILIZANDO REDES NEURAIS ARTIFICIAIS

ROBERTO MAX PROTIL; LEANDRO DOS SANTOS COELHO; WESLEY VIEIRA DA SILVA;

PONTIFÍCIA UNIVERSIDADE CATÓLICA DO PARANÁ

CURITIBA - PR - BRASIL

protil@ppgia.pucpr.br

APRESENTAÇÃO SEM PRESENÇA DE DEBATEDOR

COMERCIALIZAÇÃO, MERCADOS E PREÇOS AGRÍCOLAS

Avaliação da previsibilidade dos preços da madeira de Eucalipto utilizando redes neurais artificiais

Grupo de Pesquisa: Comercialização, Mercados e Preços Agrícolas

1 INTRODUÇÃO

A representação dinâmica de um sistema dinâmico por um conjunto de equações matemáticas é essencial para o desenvolvimento de sistemas computacionais de identificação e previsão de comportamento dinâmico de sistemas complexos. As técnicas de previsão de séries temporais clássicas — Holt, Holt-Winters, modelos auto-regressivos (AR), modelos Box-Jenkins, *Generalised Auto-Regressive Conditionally Heteroscedastic* (GARCH), entre outras — são implementadas usualmente considerando a hipótese do “bom” conhecimento da dinâmica das séries temporais e a possível presença de características de tendência, sazonalidade e nível. Estas técnicas, no entanto, muitas vezes,

podem não providenciar resultados satisfatórios quando aplicadas a sistemas dinâmicos não-lineares e/ou com comportamento caótico, estes modelados como processos lineares (KANTZ & SCHREIBER, 1997)

A teoria e prática de identificação de sistemas lineares estão bem estabelecidas na literatura (LJUNG, 1987), entretanto a utilização de modelos matemáticos lineares para representar sistemas não-lineares é limitada, pois tais representações não podem reproduzir comportamentos dinâmicos, tais como histerese, bifurcações, incertezas, acoplamentos não-lineares, que resultam em interações não-lineares. Neste caso, técnicas de previsão de séries temporais não-lineares são necessárias para modelar tais comportamentos (Billings & Coca, 1999).

A identificação e/ou previsão de comportamento dinâmico de um sistema não-linear é usualmente uma tarefa difícil. Entretanto, diversas abordagens têm sido propostas na literatura recentemente para esta tarefa (BU & HUNG, 1999; ZHU, 2000;; SWAIN & BILLINGS, 2001; KABOUDAN, 2001; PREVIDI, 2002; PILGRAM *et al.*, 2002; COULIBALY & BALDWIN, 2005). Um substancial interesse tem sido focado na utilização de redes neurais para identificação de sistemas não-lineares (TAN *et al.*, 1995; PAN *et al.*, 2001; HUANG & LOH, 2001; HOO *et al.*, 2002; RANK, 2003; GAO & ER, 2005).

As redes neurais função de base radial (RNs-RBF) formam uma classe de redes neurais que possuem certas vantagens em relação a outros tipos de redes neurais, incluindo melhor capacidade de aproximação, estruturas simples e algoritmos de aprendizado rápido (SARIMVEIS *et al.*, 2002).

Neste artigo é apresentada uma RN-RBF que utiliza o método de agrupamento de Gustafson-Kessel (GUSTAFSON & KESSEL, 1979) para o ajuste dos centros das funções Gaussianas (funções de ativação) e otimização dos centros (busca local) e das aberturas (*spreads*) das funções Gaussianas através de evolução diferencial (STORN & PRICE, 1995). As etapas abordadas, neste artigo, para a previsão de séries temporais através da RN-RBF incluem a determinação de uma classe de modelos candidatos (estrutura do modelo neural), um critério para verificação da aproximação entre os dados reais e o modelo matemático obtido, e o desenvolvimento de rotinas matemáticas de validação dos modelos matemáticos resultantes. O projeto da RN-RBF é validado para previsão, a curtíssimo prazo, do preço da madeira de eucalipto para celulose. O desempenho do projeto otimizado da RN-RBF baseado nos resultados de previsão é apresentado e discutido na seção de apresentação dos resultados de previsão.

O artigo está organizado da seguinte maneira. O estudo de caso de previsão dos preços da madeira de eucalipto para celulose é descrito brevemente na seção 2. Os conceitos básicos da RN-RBF e da otimização através de agrupamentos e evolução diferencial são detalhados na seção 3. Os resultados obtidos da previsão de curto prazo são apresentados e analisados na seção 4 e a conclusão é mencionada na seção 5.

2 ESTUDO DE CASO: PREVISÃO DOS PREÇOS DE MADEIRA DE EUCALIPTO PARA CELULOSE

O cenário atual do setor florestal brasileiro demonstra os reflexos da exploração predatória das florestas naturais causadas, principalmente, pela expansão da fronteira agropecuária, pelas atividades de mineração, e pela produção de carvão vegetal a partir do cerrado, notadamente, em Minas Gerais e estados do Centro-Oeste. A falta de uma política de

monitoramento da exploração, via manejo sustentado, também contribuiu para agravar a situação. O exemplo maior deste fato é a atual demanda de madeira serrada de eucalipto no mercado, em substituição às madeiras consideradas nobres, advindas da Mata Atlântica e Floresta Amazônica.

As florestas de eucalipto implantadas no Brasil, é sempre bom lembrar, visavam, até a pouco tempo, atender principalmente a indústria siderúrgica (carvão vegetal) e a de papel e celulose. Vale ressaltar que, existem vários problemas na utilização desta floresta na produção madeira serrada, pois as características selecionadas das árvores visavam maximizar a produção de carvão vegetal e de papel e celulose.

Em decorrência deste fato, nota-se uma movimentação das empresas florestais, instituições de pesquisa e Universidades especializadas no ramo, na procura de meios de viabilização da utilização destas florestas, assim como na redução das perdas no processamento. Por conseguinte, planejar e implantar florestas, com características desejáveis para produção de madeira serrada, é um desafio para o futuro (MADEIRA, 2003).

A administração florestal é um processo de decisão, o qual, pelo tempo gasto na produção florestal, possui características próprias de decisão. Os administradores florestais, por exemplo, precisam realizar decisões que influenciarão a espécie, qualidade e quantidade das essências florestais dos futuros recursos florestais. Conseqüente muitas das decisões tomadas no presente serão julgadas em um ambiente futuro diferente do atual (THOMPSON, 1968:156). O problema de incerteza na gestão de florestas é freqüentemente discutido na literatura florestal, todavia há poucos estudos sobre a utilização de métodos não convencionais na avaliação de risco no planejamento florestal (PROTIL, 1993:12).

A questão de previsão dos preços de madeira para o mercado brasileiro foi tratada por PROTIL (1994), o qual desenvolveu um sistema computacional para avaliação de riscos em investimentos florestais. O sistema possuía um módulo de previsão dos preços de madeira de eucalipto para a indústria de madeira compensada baseado no modelo de oscilação aleatória de ativos financeiros proposto por FAMA (1968).

O desenvolvimento de métodos de previsão do preço da madeira de eucalipto pode ser útil ao planejamento estratégico das empresas florestais a curto e médio prazo, pois permitiriam elaborar cronogramas sustentáveis de plantio e corte de árvores. Estes métodos também podem levar a uma maior maximização da produção e alcançar os usos múltiplos das florestas, que recebem cuidados especiais através do plantio de reposição. A série temporal abordada neste trabalho é dos preços (em US\$ médio) de toras (em m³ estaleiro) de eucalipto para celulose de agosto de 1997 a dezembro de 2004.

3 REDE NEURAL FUNÇÃO DE BASE RADIAL COM OTIMIZAÇÃO POR EVOLUÇÃO DIFERENCIAL

As redes neurais artificiais (RNs) são motivadas por sistemas neurais biológicos, com intenção de simular, mesmo que rudimentarmente, a forma como o cérebro aprende, recorda e processa informações. As RNs são projetadas como um sistema interconectado de elementos de processamento (neurônios), cada um dos quais com um número limitado de entradas e saídas.

Entre as características que melhor explanam o potencial das redes neurais sobressaem-se a adaptabilidade, paralelismo, multidisciplinaridade e tolerância a falhas, o que proporciona uma ferramenta matemática promissora para aplicações práticas. As RNs proporcionam,

usualmente, conhecimento quantitativo não-paramétrico e são adequadas para previsão de sereis temporais e aprendizado de sistemas complexos, pois são aproximadores universais de funções (LO, 1998).

Uma função de base radial, ϕ , em que a saída é simétrica em torno de um centro associado, μ_c , tal que $\phi_c = \phi(\|x - \mu_c\|)$, onde $\|\cdot\|$ é um vetor norma. Muitas funções são utilizadas como funções de base, na camada intermediária de uma rede neural de base radial, tais como funções de aproximação cúbica, multiquadrática e *thin plate spline*.

Uma condição suficiente para uma função ser candidata à função de base radial é a de ser radialmente simétrica e a sua primeira derivada deve ser monotônica (POGGIO & GIROSI, 1990). As funções Gaussianas são um tipo de função de base radial muito utilizadas. As funções Gaussianas são caracterizadas por um parâmetro de escala (ou comprimento), σ , e podem ser representadas por

$$\phi_c(x) = \phi(\|x - \mu_c\|; \sigma) \quad (1)$$

Um conjunto de funções de base radial pode servir como uma base para a representação de uma vasta classe de funções que são expressas como combinações lineares de funções de base radial escolhidas, tal que:

$$y(x) = \sum_{j=1}^M \omega_j \phi(\|x - \mu_c\|) \quad (2)$$

Uma RN-RBF, conforme apresentada na figura 1, é um agrupamento de equações na forma de uma rede neural *feedforward* com três camadas: a(s) entrada(s), camada oculta (intermediária) e camada(s) de saída. Cada unidade oculta representa uma função de base radial simples com comprimento e posição do centro associados. As unidades ocultas são algumas vezes denominadas de centróides ou núcleos. Cada unidade de saída executa uma soma ponderada de unidades ocultas, utilizando os valores de ω_j como pesos.

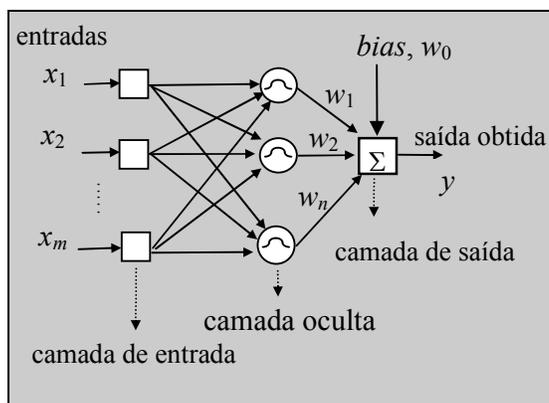


Figura 1. Uma RN-RBF com uma camada intermediária.

A abordagem de determinar os componentes individuais sendo dada uma superposição de Gaussianas foi explorado nos anos 1960. Subseqüentemente, a utilização de funções de base radial para interpolação numérica e aproximação de funções foi demonstrada por POWELL (1985). O projeto da RN-RBF adotado, neste artigo, é o do treinamento em dois estágios, que são os seguintes: (i) determinar o número de centros e dos valores de μ_c e

σ_j , e (ii) determinar os pesos das unidades da saída para os centros e comprimentos obtidos no estágio (i).

No primeiro estágio pode-se utilizar um algoritmo de aprendizado supervisionado ou não-supervisionado (por exemplo, mapas auto-organizáveis de Kohonen). Neste artigo, adota-se um método da computação evolutiva denominado evolução diferencial (STORN & PRICE, 1995) para otimização dos centros (junto ao método de agrupamento de dados de Gustafson-Kessel) e largura das funções de ativação Gaussianas. No segundo estágio, o ajuste dos pesos das unidades de saída é realizado pela técnica da pseudo-inversa (GOLUB & VAN LOAN, 1983).

2.1 Evolução diferencial

Os algoritmos evolutivos ou evolucionários (AEs) são ferramentas computacionais promissoras para busca, otimização, aprendizado de máquina e para resolução de problemas de projeto. Estes algoritmos utilizam a evolução simulada buscando soluções para problemas complexos (Bäck *et al.*, 1997). Os AEs são baseados em uma população de indivíduos, onde cada um representa um ponto de busca no espaço de soluções potenciais para um dado problema. Os AEs possuem alguns procedimentos de seleção baseados na aptidão dos indivíduos (vetores solução), operadores de cruzamento e mutação.

Os AEs incluem algoritmos genéticos, programação evolucionária, estratégias evolutivas, programação genética, entre outras variantes (BÄCK *et al.*, 1997). Dentre as variantes de AEs destaca-se o recentemente proposto algoritmo de ED. A ED foi desenvolvida por PRICE & STORN (1995) e visa a busca por melhores resultados com uma abordagem um pouco diferente da utilizada nos algoritmos genéticos, mas com similaridades de implementação com as estratégias evolutivas. Na ED a mutação não é realizada por uma função densidade de probabilidade. Algumas das potencialidades da ED são a rapidez de convergência da otimização e a facilidade de implementação.

Neste artigo enfoca-se a ED, proposta originalmente por STORN & PRICE (1995), que apesar de apresentar conceitos simples é de fácil implementação, robusta e eficiente para a minimização de funções não-lineares e não-diferenciáveis no espaço contínuo. Na ED, os parâmetros da função a ser otimizada são codificados com variáveis representadas em ponto flutuante na população e são realizadas mutações simples com uma operação aritmética simples. STORN (1997) relatou resultados impressionantes que mostram que a ED supera outros AEs (*simulated annealing* adaptativo, Nelder e Mead com *annealing*, algoritmo genético, estratégia evolutiva e equações diferenciáveis estocásticas) para abordagens de minimização em relação ao número de avaliações necessárias localizando o mínimo global de diversas funções teste consolidadas na literatura.

A escolha da ED para otimização da RN-RBF foi baseada nas seguintes características (CHENG & HWANG, 2001):

- é um algoritmo de busca estocástica que apresenta menor tendência de se concentrar em mínimos locais, pois a busca pelo ótimo global é feita através da manipulação de uma população de soluções ou, em outras palavras, por uma busca simultânea em diferentes áreas do espaço de soluções;
- é eficiente para problemas de otimização de funções objetivo que não requerem informações relativas à derivadas;
- permite que os parâmetros de entrada e saída sejam representados como ponto flutuante

sem nenhum esforço computacional adicional (como é o caso da representação binária dos algoritmos genéticos);

- não necessita manter um tamanho grande de população.

Existem duas variantes da ED que têm sido reportadas na literatura, a ED/*rand/1/bin* e a ED/*best/2/bin* (STORN, 1997). As diferentes variantes são classificadas usando a seguinte notação: ED/ $\alpha/\beta/\delta$, onde α indica o método de seleção dos indivíduos genitores que formarão o vetor base que passa pela operação de mutação, o β indica o número de vetores de diferenças utilizados para perturbar os indivíduos do vetor base e δ indica o mecanismo de cruzamento utilizado para geração da população de indivíduos descendentes. A sigla *bin* indica que a operação de cruzamento é controlada por uma série de experimentos binomiais.

A implementação de ED adotada neste artigo, é a ED/*rand/1/bin*. Neste caso, cada variável de um indivíduo (vetor) da população é representada por um valor real (ponto flutuante) e o seu procedimento de otimização para o problema de despacho econômico é regido pelas seguintes etapas:

(i) *gerar a população inicial*: gerar de forma aleatória com distribuição uniforme uma população inicial (geração $G=0$) de soluções factíveis, onde é garantido por regras de “reparo” que os valores atribuídos as variáveis estão dentro das fronteiras delimitadas pelo projetista;

$$P_i^j(G=0) = \lim_{inf}(P_i) + rand_i[0,1] * \{ \lim_{sup}(P_i) - \lim_{inf}(P_i) \} \quad (3)$$

onde $j=1, \dots, M$ indivíduos, M é o tamanho da população ($M > 4$), n é a dimensão da solução, $\lim_{inf}(P_i)$ e $\lim_{sup}(P_i)$ são os limites inferior e superior de valores admissíveis para a variável x_i , respectivamente, e $rand_i[0,1]$ gera um número aleatório, com distribuição uniforme, no intervalo entre 0 e 1.

(ii) *avaliar a população*: para cada indivíduo é avaliada a função de aptidão (a ser maximizada), F_a^j , $j=1, \dots, M$. Neste artigo, adotou-se uma função de aptidão dada pela média harmônica do índice de correlação múltipla, R^2 , obtidos nas fases de estimação e validação;

$$F_a^j(G) = \frac{2R_{est}^2 R_{val}^2}{R_{est}^2 + R_{val}^2} \quad (4)$$

onde R_{est}^2 e R_{val}^2 são os índices de correlação múltipla das fases de estimação e validação da previsão da série temporal dos preços das toras de eucalipto. Neste caso, o coeficiente de correlação múltipla, R^2 , entre a saída real, $y(t)$, e saída estimada (prevista), $\hat{y}(t)$, dado por

$$R^2 = 1 - \frac{\sum_{k=1}^N [y(t) - \hat{y}(t)]^2}{\sum_{k=1}^N [y(t) - \bar{y}]^2} \quad (5)$$

onde \bar{y} é a média das N amostras medidas. Quando o valor de R^2 é igual a 1,0 indica uma exata adequação do modelo para os dados medidos do histórico da série temporal.

(ii) *selecionar indivíduos*: um indivíduo $P_i^j(G)$, da i -ésima unidade geradora na G -ésima geração, é selecionado de forma aleatória, para ser substituído e outros três diferentes indivíduos r_1, r_2, r_3 (valores inteiros do indivíduo i da população) são selecionados aleatoriamente como genitores;

(iii) *operação de mutação*: um destes três indivíduos é selecionado como genitor principal (por exemplo, r_1) e com alguma probabilidade, cada variável do genitor principal é modificada. Neste caso, pelo menos uma variável deve ser alterada. A modificação é realizada adicionando ao valor atual da variável um fator de mutação, F , regida pela diferença entre dois valores desta variável nos outros dois genitores, ou seja,

$$P_i(G+1) = P_{i,r_1}(G) + F (P_{i,r_2}(G) - P_{i,r_3}(G)) \quad (6)$$

Em outras palavras, o vetor denominado genitor principal é modificado baseado no vetor de variáveis de dois outros genitores.

(iv) *operação de cruzamento*: seguindo a operação de mutação, o cruzamento é aplicado na população. Para cada vetor mutado, $P_i(G+1)$, um índice $rnbr(i) \in \{1, 2, \dots, n\}$ é aleatoriamente escolhido, e um vetor tentativa, $P_{t_i}(G+1)$ é gerado tal que

$$P_{t_i,q}(G+1) = \begin{cases} P_{i,q}(G+1), & \text{se } randb(q) \leq CR \text{ ou } q = rnbr(i) \\ P_{i,q}(G), & \text{se } randb(q) > CR \text{ ou } q \neq rnbr(i) \end{cases} \quad (7)$$

onde $i=1, \dots, n$ é um índice de indivíduo da população e $q=1, \dots, n$ é a posição do indivíduo n -dimensional. Para decidir se o vetor $P_{t_i}(G+1)$ deve ser um membro da população na próxima geração, este é comparado com o vetor $P_i(G+1)$ correspondente. Se o vetor $P_{t_i}(G+1)$ apresenta uma função de aptidão melhor que a escolhida à substituição, ele a substitui; caso contrário, o vetor escolhido $P_i(G+1)$ para ser substituído é mantido na população.

(v) *critério de parada*: incrementar uma unidade ao valor de G ; após ir para o passo (ii) até que um critério de parada seja atendido. Neste artigo o critério de parada é o número máximo de gerações, G_{max} .

Na ED, $F > 0$ é um parâmetro real, que controla a amplificação da diferença entre dois indivíduos e para evitar a estagnação é usualmente projetado no intervalo $[0, 1; 2]$; $randb(q)$ é a q -ésima avaliação de um número aleatório com distribuição uniforme no intervalo $[0, 1]$; CR is a taxa de cruzamento (*crossover rate*) no intervalo $[0, 1]$. O desempenho da ED depende de três variáveis: o tamanho de população M , o fator de mutação F e a taxa de cruzamento CR .

3 RESULTADOS DE PREVISÃO PARA O ESTUDO DE CASO

O procedimento de previsão de séries temporais através de uma RN-RBF foi configurado para utilizar um modelo auto-regressivo (usando saídas reais passadas) com estrutura série-paralelo para previsão um passo à frente, os detalhes desta estrutura são apresentados em Van Gorp (2000).

A RN-RBF projetada para previsão de preços das toras de eucalipto consiste de 3 neurônios de entrada compostos dos vetores $\{y(t-3), y(t-2), y(t-1)\}$ e 1 neurônio na camada

de saída composto da saída estimada $\hat{y}_{t(+1)}$. Na figura 2 são apresentados os detalhes do projeto e otimização da RN-RBF.

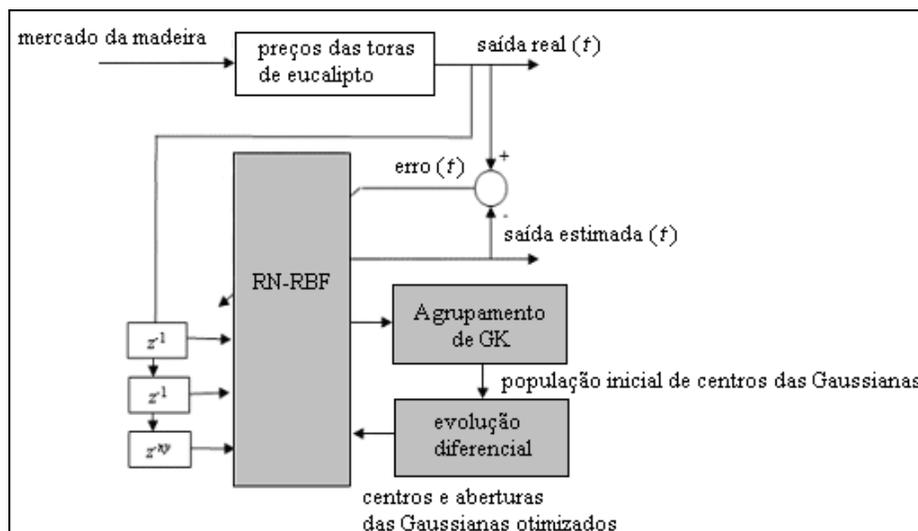


Figura 2. RN-RBF usando estrutura série-paralelo para previsão um passo à frente.

Neste estudo de caso foram utilizadas as primeiras 42 amostras (amostra 1 a 42) para a fase de estimação do modelo de previsão, com otimização com método de agrupamento de Gustafson-Kessel (GK) e ED. As 42 amostras seguintes (amostra 43 a 82) para a fase de validação (teste) do modelo de previsão de preços. Foram testados diferentes números de funções Gaussianas na camada oculta da RN-RBF e os melhores resultados dos experimentos são resumidos nas tabelas 1 a 3. Nas simulações de otimização através do ED foram utilizados os seguintes parâmetros:

- tamanho de população, M : 30 indivíduos;
- taxas de mutação e cruzamento, respectivamente, com valores $F = 0,4$ e $CR = 0,8$;
- espaço de busca dos parâmetros (centros e larguras das funções de ativação Gaussianas) entre -5 e 5 para os centros das funções Gaussianas e entre 0 e 5 para as aberturas das Gaussianas;
- experimentos: 10 (com diferentes sementes de números aleatórios para gerar a população da ED);
- critério de parada da otimização usando ED: 200 gerações.

Tabela 1: Resultados da previsão usando RN-RBF (fase de estimação).

Gaussianas na camada oculta da RN-RBF	R^2_{est} (fase de estimação do modelo de previsão)			
	Mínimo	Média	Máximo	Desvio Padrão
2	0.80032	0.79446	0.79146	0.00308
3	0.82524	0.82231	0.81001	0.00460
4	0.82499	0.82383	0.82220	0.00101
5	0.82537	0.82346	0.82172	0.00128

Tabela 2: Resultados previsão usando RN-RBF (fase de validação).

Gaussianas na camada oculta da RN-RBF	R^2_{val} (fase de validação do modelo de previsão)			
	Mínimo	Média	Máximo	Desvio Padrão
2	0.86148	0.85596	0.85422	0.00263

3	0.89772	0.89042	0.88156	0.00490
4	0.90181	0.89558	0.89059	0.00362
5	0.90424	0.89843	0.89219	0.00423

Tabela 3: Resultados de função custo na previsão usando RN-RBF.

Gaussianas na camada oculta da RN-RBF	$F_a^j(G)$ (onde $G=200$)			
	Mínimo	Média	Máximo	Desvio Padrão
2	0.82925	0.82406	0.82189	0.00269
3	0.85930	0.85499	0.84779	0.00344
4	0.86017	0.85821	0.85639	0.00120
5	0.86101	0.85931	0.85745	0.00135

Nota-se dos resultados apresentados na tabela 1, que a RN-RBF apresentou $0.79146 \leq R_{est}^2 \leq 0.82527$ com valores pequenos de desvio padrão mostrando a robustez do GK com DE para otimizar o projeto da rede neural. Os resultados da tabela 2 mostram que $0.85422 \leq R_{val}^2 \leq 0.90424$. Neste caso, a RN-RBF com 5 funções de pertinência apresentou resultados aceitáveis para o projeto de um previsor de preços para as toras de eucalipto. Entretanto, observa-se que os resultados da fase de estimação foram inferiores aos da fase de validação. Na tabela 3, observa-se que quanto maior o número de funções de ativação Gaussianas utilizadas na camada oculta da RN-RBF melhor o resultado do previsor. Entretanto, quanto mais complexa (mais parâmetros) apresentar o projeto da RN-RBF maior custo computacional e maior dificuldade de obtenção de um procedimento de otimização eficiente para a RN-RBF. Em outras palavras, a complexidade da otimização através de ED cresce com o aumento do número de funções de ativação utilizadas no modelo de previsão, pois a ED necessita neste caso otimizar mais centros e larguras das funções de ativação Gaussianas. Nas figuras 3 a 6 são apresentados os melhores resultados obtidos para os números de funções de ativação da RN-RBF testadas. Na figura 7 são apresentados os resultados da otimização do melhor solução da ED (média de 10 experimentos) para o projeto da RN-RBF usando 4 e 5 funções Gaussianas na camada oculta.

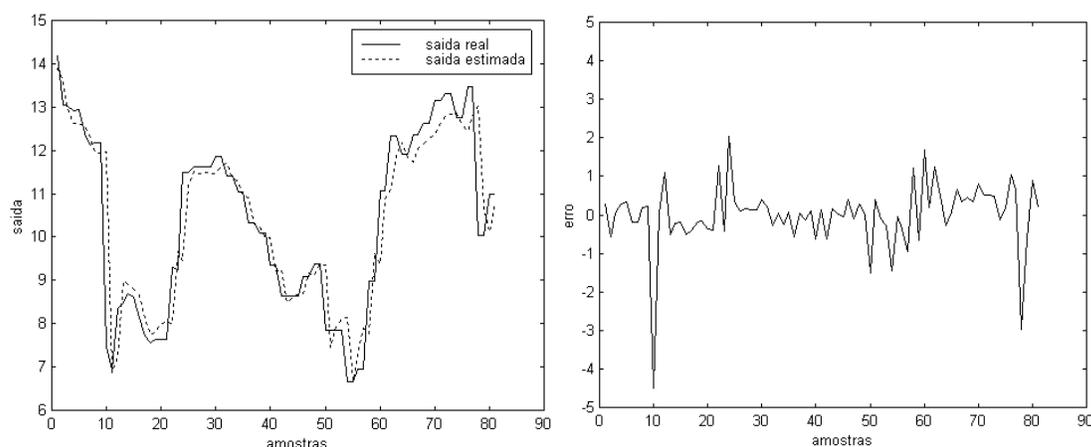


Figura 3. Melhor resultado de previsão pela RN-RBF usando 2 funções Gaussianas na camada oculta.

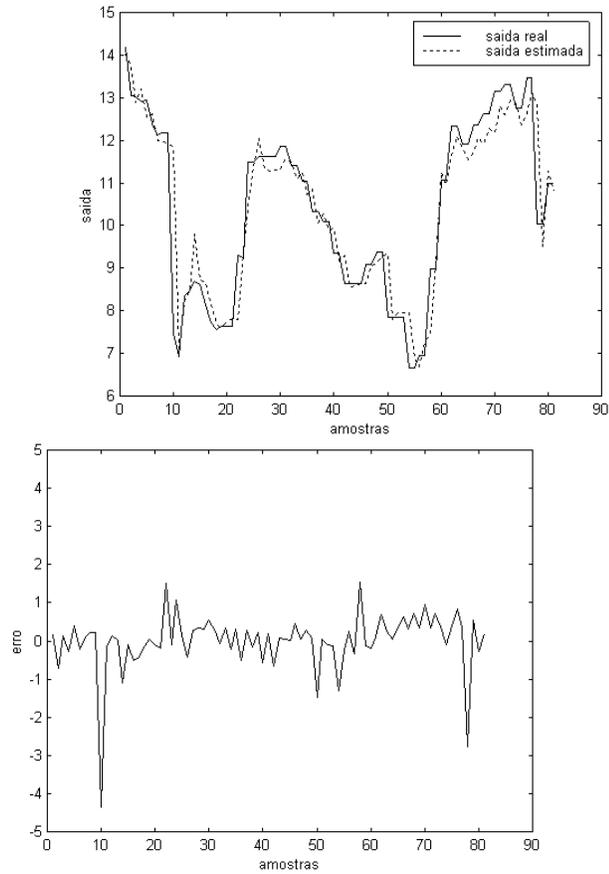


Figura 4. Melhor resultado de previsão pela RN-RBF usando 3 funções Gaussianas na camada oculta.

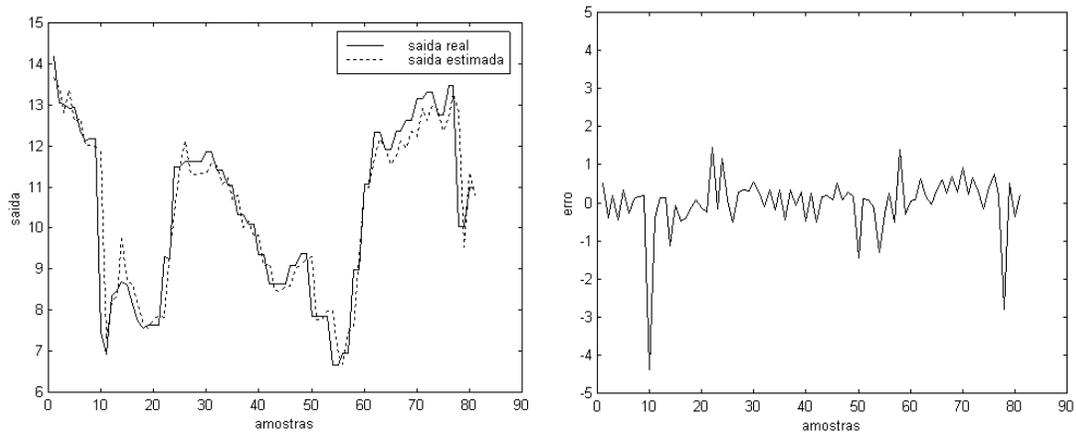


Figura 5. Melhor resultado de previsão pela RN-RBF usando 4 funções Gaussianas na camada oculta.

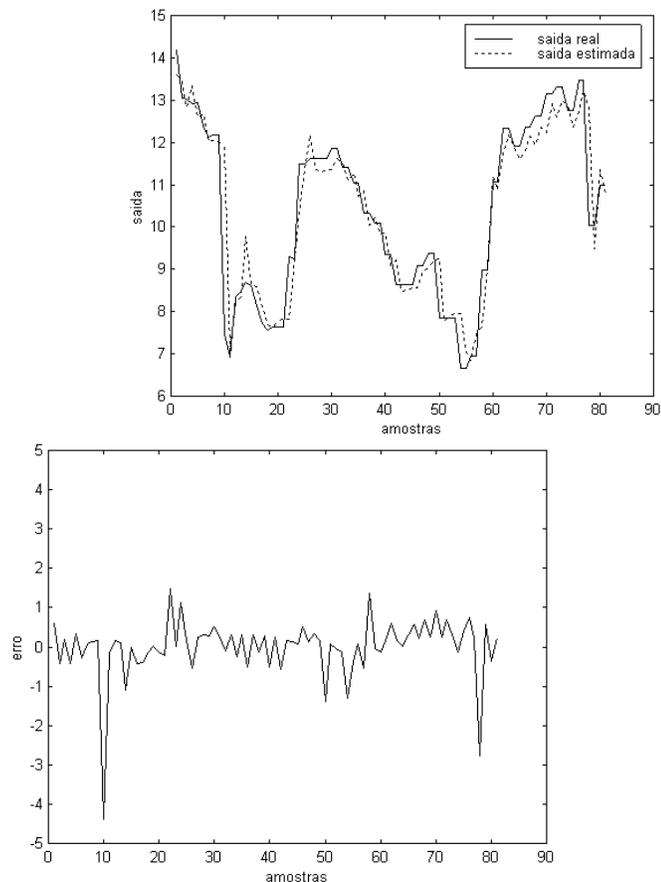
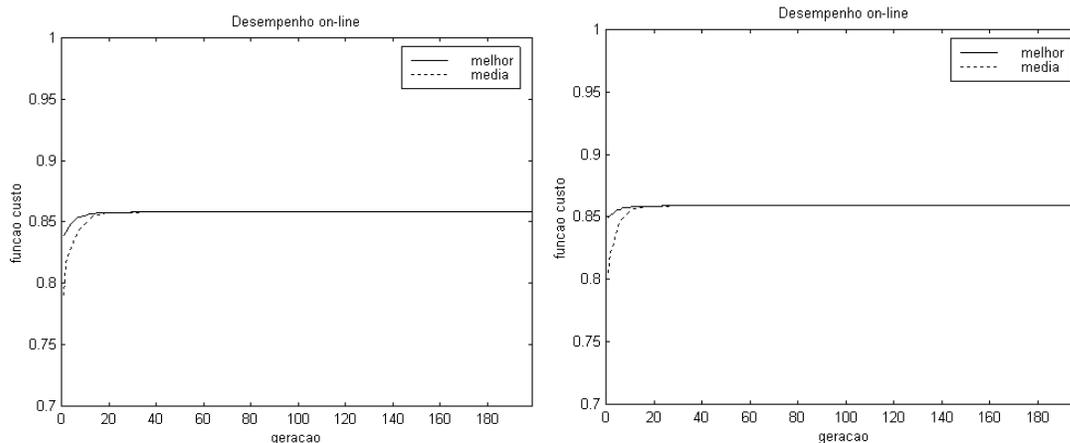


Figura 6. Melhor resultado de previsão pela RN-RBF usando 5 funções Gaussianas na camada oculta.



(a) 4 funções de ativação

(b) 5 funções de ativação

Figura 7. Resultado da otimização do melhor solução da ED (média de 10 experimentos) para o projeto da RN-RBF usando 4 e 5 funções Gaussianas na camada oculta.

5 CONCLUSÃO E PESQUISA FUTURA

A RN-RBF é uma abordagem de reconhecimento de padrões útil para o projeto de modelos matemáticos não-lineares de previsão, particularmente para sistemas que tem níveis de operação típicos, pois as RNs-RBF são aproximadores locais universais, conforme provado

por LO (1998). O aprendizado da RN-RBF é particularmente simples e rápido em relação à rede neural *perceptron* multicamadas, esta muito utilizada em aplicações de identificação de sistemas complexos e previsão não-linear de séries temporais.

Neste artigo foi apresentado um projeto de RN-RBF utilizando um procedimento de otimização baseado em agrupamento de GK e ED. O estudo de caso de previsão foi da previsão a curtíssimo prazo (um passo à frente) do preço da madeira de eucalipto para celulose. O desempenho do projeto e otimização da rede neural é detalhado também no artigo.

Uma dificuldade na configuração de RNs-RBF para aplicações de previsão de séries temporais é o aspecto relativo ao domínio temporal. Se a ordem de um sistema é conhecida, a utilização do método *tapped-delay-line* permite a um sistema dinâmico ser modelado com uma RN-RBF estática. Entretanto, quando a ordem é desconhecida, muitas aplicações podem levar o projetista a adotar um número elevado de entradas. Tal procedimento pode produzir modelos ineficientes devido ao grande número de entradas necessário. Neste contexto, estudos aprofundados são necessários quanto a análise da ordem (*lags*) de atraso na entrada da RN-RBF e também em relação à obtenção de modelos matemáticos com RNs-RBF com um melhor compromisso entre complexidade e precisão da aproximação de dinâmicas não-lineares. Neste caso, uma alternativa a ser avaliada é a utilização de abordagens de ED com múltiplos critérios.

6 REFERÊNCIAS

- BÄCK, T.; FOGEL, D. B. & MICHALEWICZ, Z. (eds.) (1997). *Handbook of Evolutionary Computation*, Bristol, Philadelphia: Institute of Physics Publishing, NY and Oxford: Oxford University Press.
- BILLINGS, S. A. & COCA, D. (1999). Discrete wavelet models for identification and qualitative analysis of chaotic systems, *International Journal of Bifurcation and Chaos*, vol. 9, no. 7, 1999, pp. 1263-1284.
- CHENG, S. -L. & HWANG, C. (2001). Optimal approximation of linear systems by a differential evolution algorithm, *IEEE Transactions on Systems, Man, and Cybernetics — Part A: Systems and Humans*, vol. 31, no. 6, pp. 698-707.
- COULIBALY, P. & BALDWIN, C. K. (2005). Nonstationary hydrological time series forecasting using nonlinear dynamic methods, *Journal of Hydrology*, vol. 307, no. 1-4, pp. 164-174.
- FAMA, E.F. (1968). The Behavior of Stock-Market Prices. *The Journal of Business*.
- GAO, Y. & ER, M. J. (2005). NARMAX time series model prediction: feedforward and recurrent fuzzy neural network approaches, *Fuzzy Sets and Systems*, vol. 150, no. 2, pp. 331-350.
- GOLUB, G. H. & VAN LOAN, C. F. (1983). *Matrix Computations*, Baltimore: The John Hopkins University Press.
- GUSTAFSON, D.E. & KESSEL, W. C. (1979). Fuzzy clustering with a fuzzy covariance matrix, *Proceedings of IEEE Conference on Control and Decision*, San Diego, CA, pp. 761-766.

- KABOUDAN, M. A. (2001). Genetically evolved models and normality of their fitted residuals, *Journal of Economic Dynamics & Control*, vol. 25, pp. 1719-1749.
- KANT, H. & SCHREIBER, T. (1997). *Nonlinear Time Series Analysis*, Cambridge University Press, Cambridge.
- LJUNG, L. (1987). *System Identification: Theory for the Use*, Prentice-Hall: New York, NY, USA.
- LO, J. T. -H. (1998). Multilayer perceptrons and radial basis functions are universal robust approximators, *International Joint Conference on Neural Networks*, Anchorage, AK, vol. 2, pp. 1311-1314.
- MADEIRA, REVISTA DA (2003). Indústria brasileira de painéis de madeira, no. 71, ano 12, maio de 2003.
- PILGRAM, B.; JUDD, K. & MEES, A. (2002). Modelling the dynamics of nonlinear time series using canonical variate analysis, *Physica D: Nonlinear Phenomena*, vol. 170, no. 2, pp. 103-117.
- POGGIO, T. & GIROSI, F. (1990). Networks for approximation and learning, *Proceedings of the IEEE*, vol. 78, no. 9, pp. 1481-1497.
- POWELL, M.J.D. (1985). Radial basis functions for multivariable interpolation: a review, *IMA Conference on Algorithms for the Approximation of Functions and Data*, pp. 143-167.
- PREVITI, F. (2002). Identification of black-box nonlinear models for lower limb movement control using functional electrical stimulation, *Control Engineering Practice*, vol. 10, pp. 91-99.
- PROTIL, R. M. (1993). Desenvolvimento de um sistema computacional para análise de risco em investimentos florestais. Dissertação de mestrado, 116 p. PPGA/UFRGS, Porto Alegre.
- PROTIL, R. M. (1994). Análise de Risco em Investimentos Florestais. 32º Congresso de Economia e Sociologia Rural. João Pessoa.
- RANK, E. (2003). Application of bayesian trained RBF networks to nonlinear time-series modeling, *Signal Processing*, vol. 83, no. 7, pp. 1393-1410.
- SARIMVEIS, H.; ALEXANDRIDIS, A.; TSEKOURAS, G. & BAFAS, G. (2002). A fast and efficient algorithm for training radial basis function neural networks based on a fuzzy partition of the input space, *Industrial Engineering Chemical Research*, vol. 41, pp. 751-759.
- STORN, R. & PRICE, K. (1995). Differential evolution: a simple and efficient adaptive scheme for global optimization over continuous spaces, *Technical Report TR-95-012*, International Computer Science Institute, Berkeley.
- STORN, R. (1997). Differential evolution — a simple and efficient heuristic for global optimization over continuous spaces, *Journal of Global Optimization*, vol. 11, no. 4, pp. 341-359.
- SWAIN, A. K. & BILLINGS, S. A. (2001). Generalized frequency response function matrix for MIMO non-linear systems, *International Journal of Control*, vol. 74, no. 8, pp. 829-844.



THOMPSON, E.F. (1968). The theory of decision under uncertainty and possible applications in forest management. *Forest Science*, volume 14, n.2, pp. 156-163.

VAN GORP, J. (2000). *Nonlinear Identification with Neural Networks and Fuzzy Logic*, Thesis, Vrije Universiteit Brussel, Faculteit Toegepaste Wetenschappen, Brussel, Belgium.

WU, B. & HUNG, S. -L. (1999). A fuzzy identification procedure for nonlinear time series: with example on ARCH and bilinear models, *Fuzzy Sets and Systems*, vol. 108, pp. 275-287.

ZHU, Y. (2000). Identification of Hammerstein models for control using ASYM, *International Journal of Control*, vol. 73, no. 18, pp. 1692-1702.