

IDENTIFICAÇÃO DE PERFIS DE TEMPERATURA E DE CONTEÚDO DE UMIDADE DE SOLOS USANDO REDES NEURAIS E MÉTODO DE AGRUPAMENTO DE DADOS

Leandro dos Santos Coelho

Laboratório de Automação e Sistemas, LAS
Programa de Graduação em Engenharia de Produção e Sistemas, PPGEPS
Pontifícia Universidade Católica do Paraná – PUCPR
Rua Imaculada Conceição, 1155, CEP 80215-901, Curitiba, PR, Brasil
leandro.coelho@pucpr.br

Roberto Freire Zanetti, Gerson Henrique dos Santos e Nathan Mendes

Laboratório de Sistemas Térmicos, LST
Programa de Pós-Graduação em Engenharia Mecânica, PPGEM
Pontifícia Universidade Católica do Paraná – PUCPR
Rua Imaculada Conceição, 1155, CEP 80215-901, Curitiba, PR, Brasil
rozafre@terra.com.br; gerson.santos@pucpr.br; nathan.mendes@pucpr.br

Resumo. Existe uma extensa gama de métodos de identificação de sistemas e formas de estruturas de modelos para escolha em aplicações de identificação de sistemas não-lineares. As redes neurais têm provado serem versáteis e úteis para a obtenção de modelos não-lineares de processos industriais. Este artigo apresenta a aplicação da rede neural função de base radial (RBF-NN) usando o método de agrupamento de dados de Gath-Geva e pseudo-inversa para identificação de perfis de transferência de calor e umidade em solos. Os resultados de simulação são promissores e mostram as potencialidades do aprendizado da RBF-NN para identificação um passo à frente de perfis de transferência de calor e umidade em solos.

Palavras chave: transferência de calor e umidade em solos, redes neurais artificiais, agrupamento de dados, identificação não-linear.

1. Introdução

Nos últimos 50 anos, a grande variedade de programas de simulação para avaliar o desempenho de sistemas térmicos em edificações tem sido desenvolvida, aprimorada e está em constante pesquisa por pesquisadores de conservação de energia em edificações. Segundo Crawley *et al.* (2005) destacam-se os programas computacionais BLAST, BSim, DeST, DOE-2.1E, ECOTECT, Ener-Win, Energy Express, Energy-10, EnergyPlus, eQUEST, ESP-r, ICE, IES <VE>, HAP, HEED, PowerDomus, SUNREL, Tas, TRACE e TRNSYS.

A maioria dos trabalhos apresentados na literatura, no que diz respeito à estimativa de temperatura em solos, levam em conta somente a condução pura de calor (Davies *et al.*, 1995). Porém sabe-se que a presença de umidade no solo fornece um mecanismo adicional de transporte, adicionando ou removendo calor latente, nos processos de condensação e evaporação.

Neste contexto, recentemente, outras ferramentas computacionais têm sido desenvolvidas no intuito de possibilitar a realização de experimentos e previsões quanto ao comportamento de temperatura e umidade no solo. Um exemplo é ambiente computacional Solum (Santos e Mendes, 2003). O Solum foi desenvolvido com o objetivo de modelar a transferência acoplada de calor e umidade em solos porosos, e consiste de uma rotina computacional com a finalidade de executar simulações rápidas e apresentar uma interface amigável para os usuários. O *software* é capaz de estimar temperatura e conteúdo de umidade em solos submetidos a diferentes condições de contorno. Entre outras características do *software* Solum, pode-se citar as visualizações gráficas de temperatura, conteúdo de umidade e fluxos de calor. As propriedades de transferência de calor e umidade em solos variáveis também podem ser visualizadas de forma gráfica e comparadas entre diferentes materiais (Freire *et al.*, 2003).

A contribuição deste trabalho é apresentar uma abordagem de redes neurais artificiais para a identificação de perfis de temperatura e umidade do solo. Os dados de temperatura e umidade relativa foram obtidos por simulação do *software* Solum para a cidade de Curitiba para um período de 1 ano.

Na área de ciências térmicas, a literatura da aplicação de métodos de identificação em sistemas térmicos possui alguns trabalhos relevantes, a citar Cunnigham (2001) e Haghghat *et al.* (1998). Entretanto, as potencialidades da utilização de redes neurais é ainda pouco explorada e poucos trabalhos têm sido apresentados, como por exemplo os trabalhos de Leung *et al.* (2001) e Chen e Chen (2000).

As redes neurais artificiais são metodologias da inteligência computacional inspiradas em estudos do cérebro e do sistema nervoso humano. As redes neurais podem ser consideradas como sistemas dinâmicos não lineares consistindo de elementos de processamento (neurônios), que são interconectados entre si, com ponderações ajustáveis (Haykin, 1996). Entre as características relevantes das redes neurais têm-se: processamento paralelo, aprendizado, memória associativa e distribuída. Estas características são inspiradas nas redes neurais biológicas. As redes neurais providenciam, usualmente, conhecimento quantitativo não-paramétrico sendo adequadas para identificação de sistemas, aprendizado e adaptação em sistemas com comportamento dinâmico complexo.

Em particular, as RNs-RBF são uma alternativa de modelo não-linear para problemas de regressão e classificação de padrões. Grande parte do interesse pelas RNs-RBF é proveniente do fato delas possuírem fundamentação estatística e são consideradas aproximadores universais de funções com dada precisão (Chen *et al.*, 1991), realizando um mapeamento das entradas de rede de dimensão vetorial m , em uma saída de dimensão vetorial n de qualquer função vetorial contínua.

O artigo é organizado da seguinte forma. A descrição da RN-RBF e o procedimento de treinamento usando agrupamento de dados são detalhados na seção 2. Na seção 3, alguns fundamentos de transferência de calor e umidade em solos insaturados são apresentados. Uma breve descrição do SOLUM e a análise dos resultados obtidos na identificação de comportamento do solo em termos de umidade relativa e temperatura pela RN-RBF são detalhadas na seção 4. Finalizando, a conclusão e comentários sobre futura pesquisa são apresentados na seção 5.

2. Rede neural de base radial

A arquitetura da RN-RBF, em sua estrutura mais básica, é constituída de três camadas, com propósitos totalmente diferentes: (i) *camada de entrada*: é composta por nós de fonte (unidades sensoriais) que conectam a rede ao seu ambiente; (ii) *camada oculta*: é única, aplica uma transformação não-linear do espaço de entrada para o espaço oculto (na maioria das aplicações, o espaço oculto é de alta dimensionalidade); e (iii) *camada de saída*: é linear, fornecendo a resposta da rede ao padrão (sinal) de ativação aplicada à camada de entrada.

O processamento da entrada de uma rede neural se realiza de acordo com sua topologia e o tipo da ativação dos neurônios. Em uma RN-RBF clássica, este aspecto consiste na alimentação adiante (*feedforward network*) de uma entrada de dimensão m em uma camada oculta (intermediária), que possui c neurônios ocultos que implementam uma função de ativação baseada em uma medida de similaridade entre os vetores de entrada e os protótipos. Cada neurônio da camada oculta possui um protótipo. As saídas da camada oculta são interligadas às unidades da camada de saída por ramos com pesos sinápticos que ponderam cada saída dos neurônios presentes na camada oculta. Cada unidade da camada de saída implementa uma soma ponderada das saídas da camada oculta. A resposta das camadas de saída forma os elementos do vetor de resposta da RN-RBF. A figura 1 mostra o diagrama em grafo de fluxo de sinal de uma RN-RBF.

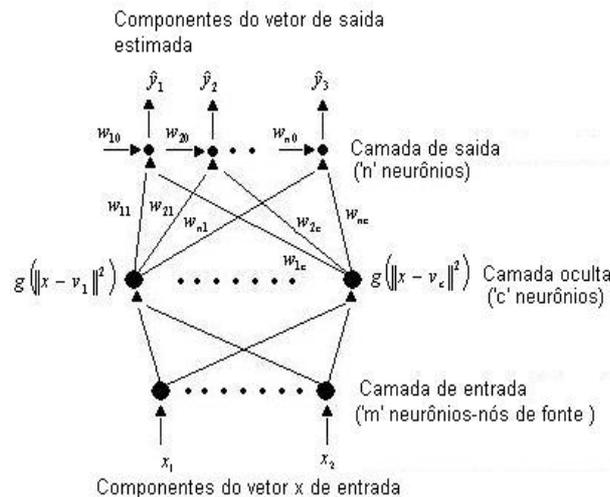


Figura 1 - Topologia de uma RN-RBF.

Uma função de base radial, ϕ , apresenta uma saída simétrica em torno de um centro associado, μ_c , tal que $\phi_c = \phi(\|x - \mu_c\|)$, onde $\|\cdot\|$ é a norma vetorial. Uma condição suficiente para uma função ser candidata à função de base radial é a de ser radialmente simétrica e possuir primeira derivada monotônica. A função Gaussiana é o tipo de função de base radial utilizada neste artigo. As funções Gaussianas são caracterizadas por um parâmetro de escala (ou comprimento), σ , e isto é verdade para muitas outras classes de funções de base radial. Tais classes podem ser representadas como:

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

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

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

Para identificação de sistemas, as RN-RBFs modelam uma função implícita de um fenômeno físico. O modelo neural de identificação é paramétrico do tipo “caixa-preta”, pois a RN-RBF contém parâmetros livres sem significado físico a serem ajustados para que a rede consiga representar a função implícita do processo.

Os vetores de protótipos e pesos sinápticos são os parâmetros da estrutura da RN-RBF. Deve-se ressaltar que os valores desses parâmetros não acrescentam nada de conhecimento a respeito do sistema, porém devem cumprir o determinado: aproximar a resposta do sistema a uma determinada entrada. Para tanto a estimação dos parâmetros das redes neurais em geral, incluindo as RNs-RBF pode ser concebido como um problema de aprendizado com uma “possível” interpretação biológica e também com equivalência matemática (problema de otimização não-linear na estimação dos parâmetros do modelo segundo um critério de otimalidade) (Haykin, 1996).

Alguns pesquisadores têm treinado as RNs-RBF, escolhendo os centros das unidades ocultas aleatoriamente no conjunto de treinamento. Outros têm utilizado métodos não-supervisionados (por exemplo, agrupamento pelo método de *k*-médias), como também algoritmos supervisionados para a seleção dos centros. Os métodos de treinamento separam as tarefas de determinação dos protótipos e a otimização dos pesos. A vantagem dessa abordagem é a rapidez no treinamento da rede como resultado da separação das tarefas e aplicação de um método híbrido de treinamento em alternativa ao treinamento global e a otimização não-linear explícita da descida de encosta (incluindo o algoritmo de retropropagação do erro) (Chen *et al.*, 1991; Chen e Liu, 1992).

A separação das tarefas no treinamento da rede é possível devido a estrutura da RN-RBF e seu tipo de função de ativação que age localmente no espaço de entrada. Foi dada uma considerável atenção na literatura das RNs-RBF em como obter um método de treinamento baseado em técnicas lineares explorando características estruturas das RNs-RBF. Observa-se na Figura 1 que se os protótipos são fixados e a função da camada escondida $g(\cdot)$ conhecida, a rede é linear em seus pesos sinápticos w . Assim, a estrutura da RN-RBF possibilita a separação de tarefas no processo de aprendizado, com a vantagem que na estimação dos pesos w o treinamento da rede se torna uma tarefa rápida de ser resolvida através de métodos de mínimos quadrados.

Segundo Chen *et al.* (1991), “o problema do mal-condicionamento nas estratégias híbridas pode, por exemplo, ocorrer devido aos centros estarem próximos, resultando em uma dependência linear entre ambos os centros”. Assim o mal-condicionamento numérico da rede pode ser contornado pelos métodos de agrupamento (*clustering*) de dados que faz a escolha dos protótipos como sendo representantes de populações encontradas nos dados de entrada por aprendizado não supervisionado. Observa-se nos métodos que exploram a localidade da RN-RBF que somente as entradas similares aos protótipos serão capazes de contribuir de forma efetiva na resposta da rede e também não usam toda informação fornecida dos exemplos de entrada(s) e saída do conjunto de treinamento na fase de estimação dos parâmetros, acarretando em uma pobre generalização no aprendizado da rede.

Existem diversos métodos de agrupamento que podem ser utilizados para o ajuste dos centros da RN-RBF, tais como o *k*-médias (e suas variantes), *c*-médias nebuloso e Gustafson-Kessel (Guerra, 2006). Uma alternativa a estes métodos é o algoritmo de Gath-Geva (Gath e Geva, 1989a, 1989b), utilizado em sistemas nebulosos (Abonyi *et al.*, 2002, 2005), que emprega uma distância da norma baseado em estimativas nebulosas de probabilidade máxima (FMLE – *Fuzzy Maximum Likelihood Estimates*), proposta por Bezdek e Dunn (1975). Neste contexto, o algoritmo de agrupamento de dados Gath-Geva (Gath e Geva, 1989a, 1989b) utilizado para a seleção dos centros das funções Gaussianas da camada oculta da RN-RBF.

O método de ajuste linear para os parâmetros de saída da RN-RBF é a pseudo-inversa. A atualização de cada peso para o treinamento da RN-RBF utilizando esta derivação do método de mínimos quadrados (Ljung, 1987).

3. Transferência de calor e umidade em solos insaturados

As equações diferenciais parciais governantes (Philip e De Vries, 1957) para modelar a transferência de calor e umidade em meios porosos são expressas pelas equações (3) e (4), as quais foram derivadas da conservação da massa e da energia em um elemento de volume de um material poroso. A equação da conservação da energia é descrita como:

$$\rho_0 c_m(T, \theta) \frac{\partial T}{\partial t} = \nabla \cdot (\lambda(T, \theta) \nabla T) - L(T) (\nabla \cdot \mathbf{j}_v), \quad (3)$$

enquanto que a equação da conservação da massa como:

$$\frac{\partial \theta}{\partial t} = -\nabla \cdot \left(\frac{\mathbf{j}}{\rho_l} \right), \quad (4)$$

onde ρ é a densidade da matriz sólida (kg/m^3), c_m , calor específico médio (J/kgK), T , temperatura ($^{\circ}\text{C}$), t , tempo (s), λ , condutividade térmica (W/mK), L , calor latente de vaporização (J/kg), θ , conteúdo de umidade em base de volume (m^3/m^3), \mathbf{j} , fluxo total de massa ($\text{kg/m}^2 \text{K}$) e ρ_l a densidade da água (kg/m^3).

Nota-se que a equação (3) difere da equação de Fourier para o fluxo de calor transiente devido ao termo fonte responsável pela mudança de fase dentro do meio poroso. De acordo com Philip e De Vries (1957) e assumindo a hipótese de que o solo é um meio isotrópico, o fluxo de vapor é dado por

$$\frac{\mathbf{j}_v}{\rho_l} = - \left(D_{Tv}(T, \theta) \frac{\partial T}{\partial x} + D_{\theta v}(T, \theta) \frac{\partial \theta}{\partial x} \right) \mathbf{i} - \left(D_{Tv}(T, \theta) \frac{\partial T}{\partial y} + D_{\theta v}(T, \theta) \frac{\partial \theta}{\partial y} \right) \mathbf{j} - \left(D_{Tv}(T, \theta) \frac{\partial T}{\partial z} + D_{\theta v}(T, \theta) \frac{\partial \theta}{\partial z} \right) \mathbf{k}, \quad (5)$$

e o fluxo de líquido por

$$\frac{\mathbf{j}_l}{\rho_l} = - \left(D_{Tl}(T, \theta) \frac{\partial T}{\partial x} + D_{\theta l}(T, \theta) \frac{\partial \theta}{\partial x} \right) \mathbf{i} - \left(D_{Tl}(T, \theta) \frac{\partial T}{\partial y} + D_{\theta l}(T, \theta) \frac{\partial \theta}{\partial y} \right) \mathbf{j} - \left(D_{Tl}(T, \theta) \frac{\partial T}{\partial z} + D_{\theta l}(T, \theta) \frac{\partial \theta}{\partial z} + \frac{\partial K_g}{\partial z} \right) \mathbf{k}. \quad (6)$$

Deste modo, define-se o fluxo de massa total \mathbf{j} como $\mathbf{j}_v + \mathbf{j}_l$, resultando

$$\frac{\mathbf{j}}{\rho_l} = - \left(D_T(T, \theta) \frac{\partial T}{\partial x} + D_{\theta}(T, \theta) \frac{\partial \theta}{\partial x} \right) \mathbf{i} - \left(D_T(T, \theta) \frac{\partial T}{\partial y} + D_{\theta}(T, \theta) \frac{\partial \theta}{\partial y} \right) \mathbf{j} - \left(D_T(T, \theta) \frac{\partial T}{\partial z} + D_{\theta}(T, \theta) \frac{\partial \theta}{\partial z} + \frac{\partial K_g}{\partial z} \right) \mathbf{k}, \quad (7)$$

onde

$D_T = D_{Tl} + D_{Tv}$ e $D_{\theta} = D_{\theta l} + D_{\theta v}$, onde D_{Tl} é o coeficiente de transporte na fase líquida associado ao gradiente de temperatura, D_{Tv} , é o coeficiente de transporte na fase vapor associado ao gradiente de temperatura, $D_{\theta v}$, é o coeficiente de transporte na fase vapor associado ao gradiente de conteúdo de umidade, D_T , coeficiente de transporte de massa associado ao gradiente de temperatura ($\text{m}^2/\text{s}^{\circ}\text{K}$), D_{θ} , coeficiente de transporte de massa associado ao gradiente de conteúdo de umidade (m^2/s) e K_g , a condutividade hidráulica (m/s).

Como condição de contorno para a superfície superior, na equação associada à conservação de energia, considera-se que o solo é exposto a radiação de onda curta, convecção de calor e de massa e mudança de fase. Então, o balanço de energia torna-se:

$$-\left(\lambda(T, \theta) \frac{\partial T}{\partial y} \right)_{y=H} - (L(T)j_v)_{y=H} = h(T_{\infty} - T_{y=H}) + \alpha q_r + L(T)h_m(\rho_{v,\infty} - \rho_{v,y=H}) - \varepsilon R_{ol}, \quad (8)$$

onde $h(T_{\infty} - T_{y=H})$ representa o calor trocado com o ar exterior por convecção, αq_r é a radiação absorvida por onda curta, R_{ol} representa a perda por radiação de onda longa e $h_m L(T)(\rho_{v,\infty} - \rho_{v,y=H})$, é a energia proveniente da mudança de fase. A absorvidade solar é definida como α e o coeficiente de convecção de massa como h_m que é relacionado com o h através da relação de Lewis.

O balanço de massa para a superfície superior do solo é descrito como

$$-\frac{\partial}{\partial y} \left(D_{\theta}(T, \theta) \frac{\partial \theta}{\partial y} + D_T(T, \theta) \frac{\partial T}{\partial y} \right)_{y=H} = \frac{h_m}{\rho_l} (\rho_{v, \infty} - \rho_{y=H}). \quad (9)$$

As outras superfícies foram consideradas adiabáticas e impermeáveis.

As equações (8) e (9) mostram a diferença de concentração de vapor, $\Delta\rho_v$, no lado direito da equação. Esta diferença é entre a superfície porosa e o ar e é normalmente determinada com valores de iterações anteriores de temperatura e conteúdo de umidade, resultando em um termo de instabilidade adicional.

Mendes *et al.* (2002) apresentaram um novo procedimento para calcular o fluxo de vapor, independentemente dos valores da temperatura e de conteúdo de umidade, das iterações anteriores. Para isto, linearizou-se o termo $\Delta\rho_v$ como uma combinação linear da temperatura e do conteúdo de umidade.

4. Identificação da transferência de calor e umidade em solos usando RN-RBF

A identificação de sistemas é uma área do conhecimento que envolve o estudo de formas de modelar e analisar matematicamente fenômenos a partir de dados. A idéia da identificação de sistemas é permitir a elaboração do modelo matemático de um sistema dinâmico baseado em medidas coletadas pelo ajuste de parâmetros e/ou do modelo matemático, até que a saída do sistema aproxime, de forma adequada, os valores de saída desejada (Johansson, 1993).

Um estudo de caso de identificação de temperatura e umidade do solo para diferentes profundidades é apresentado neste trabalho. Usando o software Solum foram obtidos os dados necessários para a realização desta tarefa. Para evitar os efeitos das condições iniciais aplicadas ao software SOLUM, foram simuladas para um período de 10 anos, os dados apresentados no arquivo e utilizados no procedimento de identificação são do último ano simulado. Neste caso, foram utilizadas 8760 amostras (1 amostra coletada a cada hora), ou seja, a variação da temperatura e umidade do solo, para um período de 1 ano para a cidade de Curitiba (Paraná). Foram utilizadas as 4000 primeiras amostras na fase de estimação e as amostras seguintes (4002 até 8760) na fase de validação da RN-RBF.

Os dados climáticos de temperatura ambiente ($u_1(t)$), umidade relativa ($u_2(t)$), radiação direta ($u_3(t)$) e radiação difusa ($u_4(t)$) são utilizados como vetores de entrada da RN-RBF, adicionado a este o vetor de saída desejado (temperatura ou umidade relativa) com um instante de tempo de atraso. Na figura 2 são mostrados os dados de temperatura ambiente, umidade relativa, radiação direta e radiação difusa usados nas simulações de estimação e validação da RN-RBF.

O procedimento de análise da identificação através de RN-RBF é dividido nas seguintes etapas: (i) escolha da estrutura da RN-RBF para representar o sistema a ser identificado, (ii) otimização da RN-RBF usando agrupamento de dados e pseudo-inversa; (iii) estimação dos parâmetros do modelo matemático (*fase de estimação*), e (iv) a validação do modelo matemático (*fase de validação*).

Na procura de um modelo “ideal”, devem ser observadas as seguintes questões: se o modelo encontrado é flexível o suficiente e se o modelo é desnecessariamente complexo, ou em outras palavras, se o modelo é confiável para o propósito desejado. Existem diversas maneiras de se realizar a validação de um modelo. Neste trabalho, o índice de desempenho utilizado é o coeficiente de correlação múltipla (R^2). O R_i^2 é um índice de desempenho calculado por:

$$R_i^2 = \frac{\sum_{t=1}^{Na} [y_i(t) - \hat{y}_i(t)]^2}{\sum_{t=1}^N [y_i(t) - \bar{y}_i(t)]^2} \quad (10)$$

onde $y_i(t)$ é a i -ésima saída real (temperatura ou umidade relativa) do sistema, $\hat{y}_i(t)$ é a i -ésima saída estimada, e $\bar{y}_i(t)$ é a i -ésima média das Na amostras medidas, e i pode ser 0 ou 1 ou 2 ou ... ou 7. Quando o valor de R_i^2 é igual a 1, indica uma exata adequação do modelo para os dados medidos do processo (Schaible *et al.*, 1997).

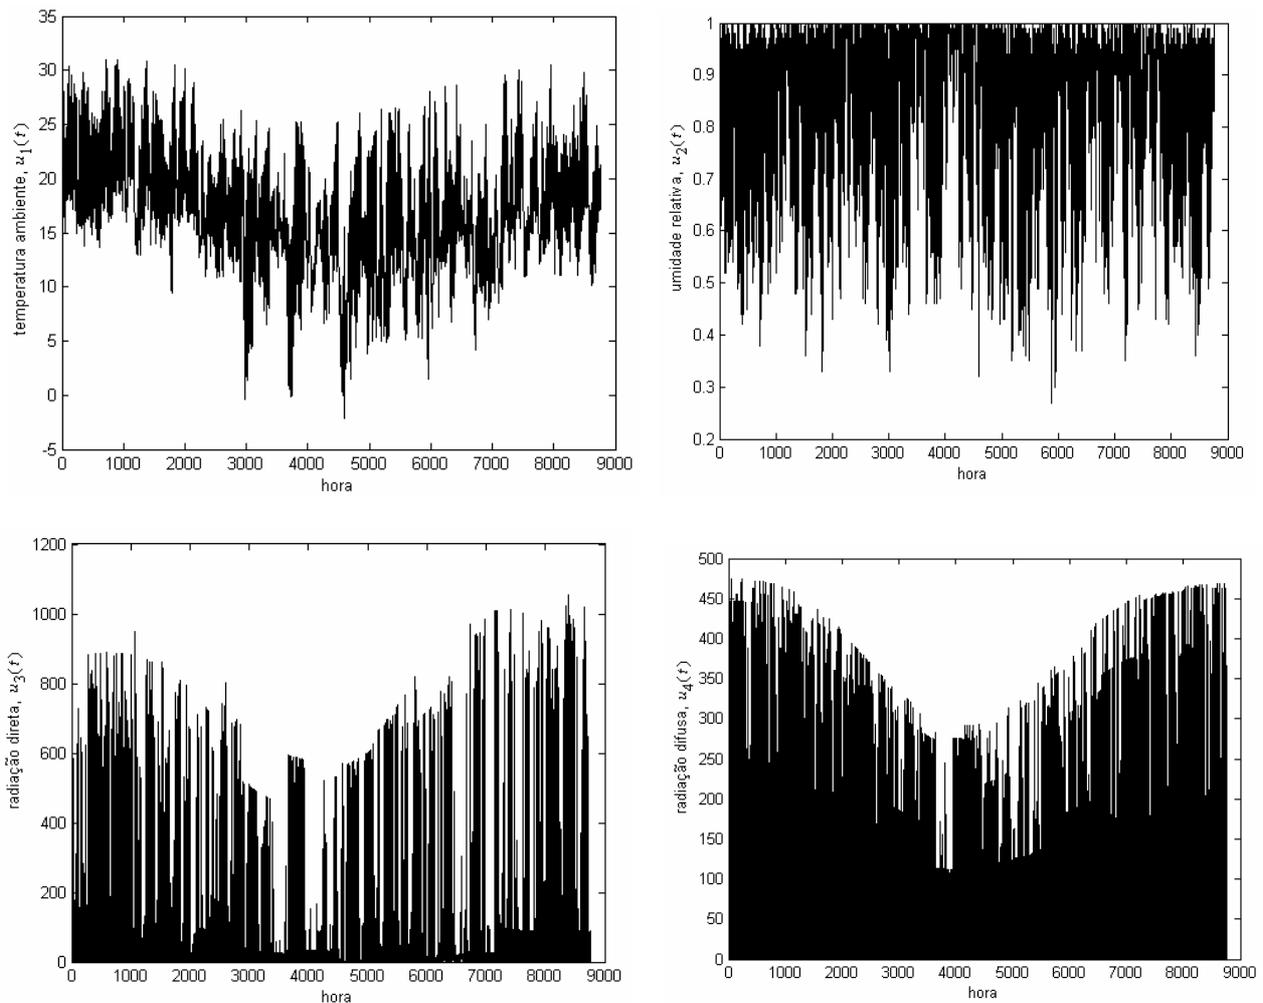


Figura 2 - Dados de temperatura ambiente, umidade relativa, radiação direta e radiação difusa.

Para identificação foi escolhido um modelo matemático para a representação do processo. A estrutura de modelo testada é o modelo multivariável *NARX* (*Nonlinear AutoRegressive with eXogenous inputs*) em concepção série-paralela com 5 entradas ($[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1)]$) e o vetor de saída com um instante de atraso e 1 saída (temperatura ou umidade relativa). A identificação do sistema térmico é apropriada se um critério de erro definido previamente pelo projetista está entre valores admissíveis às necessidades do projeto, neste caso, o objetivo é obter um maior R^2 .

Foram testadas várias configurações de rede neural para obtenção de saídas estimadas para temperatura ou umidade relativa do solo. Os resultados de previsão do modelo neural obtidos para temperatura e umidade relativa para 0m (superfície), 1m, 2m e 3m de profundidade (previsão um passo à frente) são apresentados, respectivamente, na tabelas 1 e 2. Nas tabelas 1 e 2 aparece o R_i^2 total que consiste da média harmônica dos valores de R_i^2 (estimação) e R_i^2 (validação). Além disso, a notação para o vetor de saída estimada da RN-RBF nas tabelas 1 e 2 é a seguinte:

- “^”: saída estimada pela RN-RBF, e sem “^”: saída real (temperatura ou umidade relativa do solo);
- $\hat{y}_0(t)$: temperatura estimada na superfície (0 m);
- $\hat{y}_1(t)$: temperatura estimada a 1 m da superfície;
- $\hat{y}_2(t)$: temperatura estimada a 2 m da superfície;
- $\hat{y}_3(t)$: temperatura estimada a 3 m da superfície;
- $\hat{y}_4(t)$: umidade relativa na superfície (0 m);
- $\hat{y}_5(t)$: umidade relativa estimada a 1 m da superfície;
- $\hat{y}_6(t)$: umidade relativa estimada a 2 m da superfície;
- $\hat{y}_7(t)$: umidade relativa estimada a 3 m da superfície.

As figuras 3 a 10 mostram os melhores resultados obtidos pela RN-RBF (ver tabela 1 e 2) para previsões um passo à frente de temperatura e umidade relativa.

Tabela 1. Previsão da temperatura para diferentes profundidades.

| Profundidade, i (em metros) | vetor de entrada da RN-RBF | vetor de saída da RN-RBF | M | R_i^2 (estimação) | R_i^2 (validação) | R_i^2 total |
|-------------------------------|--|--------------------------|-----|---------------------|---------------------|---------------|
| 0 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_0(t-1)]$ | $\hat{y}_0(t)$ | 2 | 0,9481 | 0,9508 | 0,9456 |
| 0 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_0(t-1)]$ | $\hat{y}_0(t)$ | 3 | 0,9513 | 0,9434 | 0,9474 |
| 0 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_0(t-1)]$ | $\hat{y}_0(t)$ | 4 | 0,9555 | 0,9504 | 0,9530 |
| 0 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_0(t-1)]$ | $\hat{y}_0(t)$ | 5 | 0,9564 | 0,9507 | 0,9535 |
| 0 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_0(t-1)]$ | $\hat{y}_0(t)$ | 6 | 0,9567 | 0,9512 | 0,9540 |
| 1 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_1(t-1)]$ | $\hat{y}_1(t)$ | 2 | 0,9928 | 0,9924 | 0,9926 |
| 1 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_1(t-1)]$ | $\hat{y}_1(t)$ | 3 | 0,9999 | 0,9999 | 0,9999 |
| 1 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_1(t-1)]$ | $\hat{y}_1(t)$ | 4 | 0,9999 | 0,9999 | 0,9999 |
| 1 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_1(t-1)]$ | $\hat{y}_1(t)$ | 5 | 0,9999 | 0,9999 | 0,9999 |
| 1 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_1(t-1)]$ | $\hat{y}_1(t)$ | 6 | 0,9999 | 0,9999 | 0,9999 |
| 2 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_2(t-1)]$ | $\hat{y}_2(t)$ | 2 | 0,9639 | 0,9608 | 0,9624 |
| 2 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_2(t-1)]$ | $\hat{y}_2(t)$ | 3 | 0,9979 | 0,9984 | 0,9982 |
| 2 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_2(t-1)]$ | $\hat{y}_2(t)$ | 4 | 0,9997 | 0,9997 | 0,9997 |
| 2 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_2(t-1)]$ | $\hat{y}_2(t)$ | 5 | 0,9991 | 0,9991 | 0,9991 |
| 2 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_2(t-1)]$ | $\hat{y}_2(t)$ | 6 | 0,9992 | 0,9991 | 0,9991 |
| 3 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_3(t-1)]$ | $\hat{y}_3(t)$ | 2 | 0,9982 | 0,9980 | 0,9981 |
| 3 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_3(t-1)]$ | $\hat{y}_3(t)$ | 3 | 0,9995 | 0,9995 | 0,9995 |
| 3 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_3(t-1)]$ | $\hat{y}_3(t)$ | 4 | 0,9996 | 0,9995 | 0,9995 |
| 3 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_3(t-1)]$ | $\hat{y}_3(t)$ | 5 | 0,9998 | 0,9998 | 0,9998 |
| 3 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_3(t-1)]$ | $\hat{y}_3(t)$ | 6 | 0,9998 | 0,9999 | 0,9998 |

Tabela 2. Previsão da umidade relativa para diferentes profundidades.

| Profundidade, i (em metros) | vetor de entrada da RN-RBF | vetor de saída da RN-RBF | M | R_i^2 (estimação) | R_i^2 (validação) | R_i^2 total |
|-------------------------------|--|--------------------------|-----|---------------------|---------------------|---------------|
| 0 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_4(t-1)]$ | $\hat{y}_4(t)$ | 2 | 0,9869 | 0,9906 | 0,9888 |
| 0 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_4(t-1)]$ | $\hat{y}_4(t)$ | 3 | 0,9956 | 0,9974 | 0,9965 |
| 0 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_4(t-1)]$ | $\hat{y}_4(t)$ | 4 | 0,9965 | 0,9980 | 0,9972 |
| 0 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_4(t-1)]$ | $\hat{y}_4(t)$ | 5 | 0,9956 | 0,9961 | 0,9958 |
| 0 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_4(t-1)]$ | $\hat{y}_4(t)$ | 6 | 0,9964 | 0,9980 | 0,9971 |
| 1 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_5(t-1)]$ | $\hat{y}_5(t)$ | 2 | 0,3593 | 0,4920 | 0,4153 |
| 1 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_5(t-1)]$ | $\hat{y}_5(t)$ | 3 | 0,9811 | 0,9924 | 0,9867 |
| 1 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_5(t-1)]$ | $\hat{y}_5(t)$ | 4 | 0,8863 | 0,9495 | 0,9168 |
| 1 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_5(t-1)]$ | $\hat{y}_5(t)$ | 5 | 0,9996 | 0,9995 | 0,9997 |
| 1 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_5(t-1)]$ | $\hat{y}_5(t)$ | 6 | 0,9995 | 0,9995 | 0,9995 |
| 2 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_6(t-1)]$ | $\hat{y}_6(t)$ | 2 | 0,7115 | 0,7501 | 0,7307 |
| 2 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_6(t-1)]$ | $\hat{y}_6(t)$ | 3 | 0,9990 | 0,9989 | 0,9990 |
| 2 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_6(t-1)]$ | $\hat{y}_6(t)$ | 4 | 0,9998 | 0,9998 | 0,9998 |
| 2 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_6(t-1)]$ | $\hat{y}_6(t)$ | 5 | 0,9997 | 0,9997 | 0,9997 |
| 2 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_6(t-1)]$ | $\hat{y}_6(t)$ | 6 | 0,9998 | 0,9997 | 0,9997 |
| 3 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_7(t-1)]$ | $\hat{y}_7(t)$ | 2 | 0,1024 | 0,1024 | 0,1024 |
| 3 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_7(t-1)]$ | $\hat{y}_7(t)$ | 3 | 0,1137 | 0,1135 | 0,1136 |
| 3 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_7(t-1)]$ | $\hat{y}_7(t)$ | 4 | 0,9896 | 0,9690 | 0,9792 |
| 3 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_7(t-1)]$ | $\hat{y}_7(t)$ | 5 | 0,9996 | 0,9990 | 0,9993 |
| 3 | $[u_1(t-1); u_2(t-1); u_3(t-1); u_4(t-1); y_7(t-1)]$ | $\hat{y}_7(t)$ | 6 | 0,9994 | 0,9990 | 0,9992 |

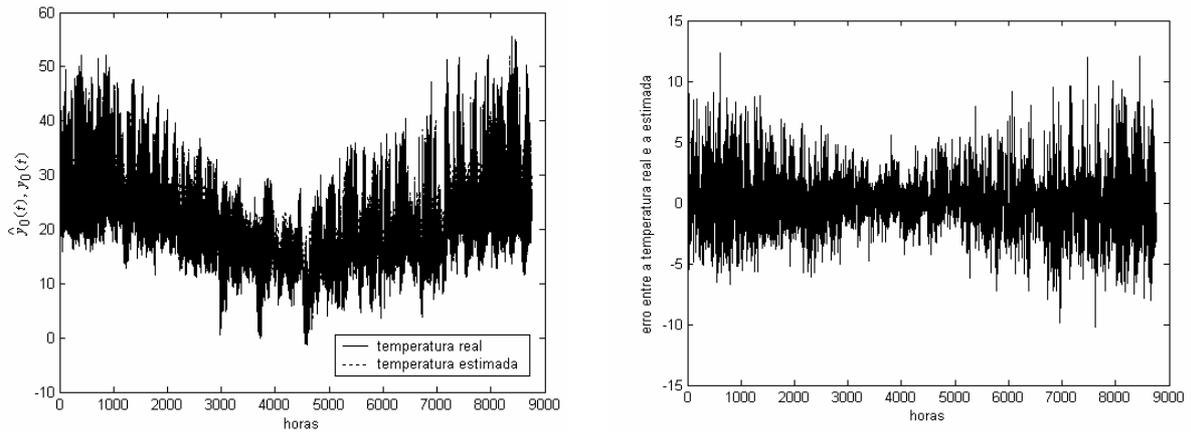


Figura 3 – Temperatura estimada na superfície (0 m) usando uma RN-RBF.

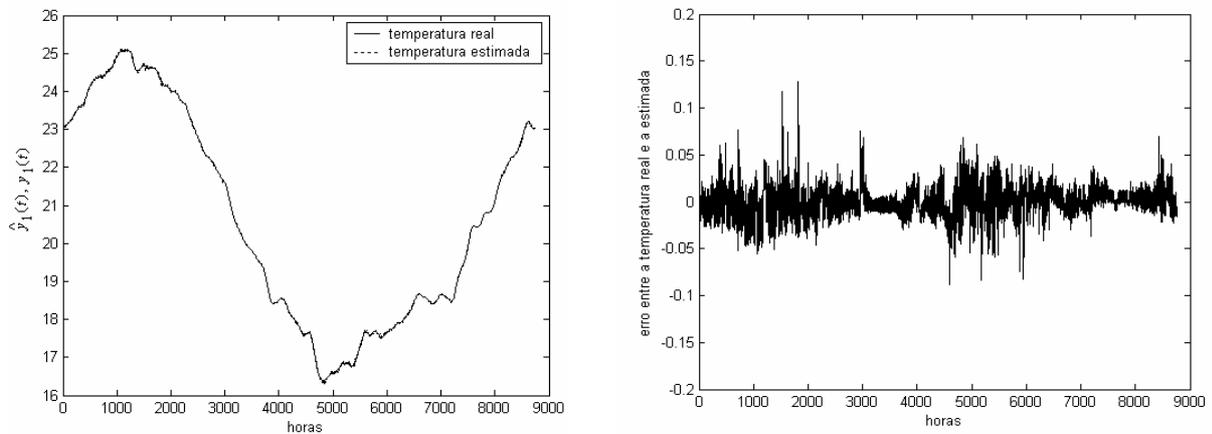


Figura 4 – Temperatura estimada a 1 m da superfície usando uma RN-RBF.

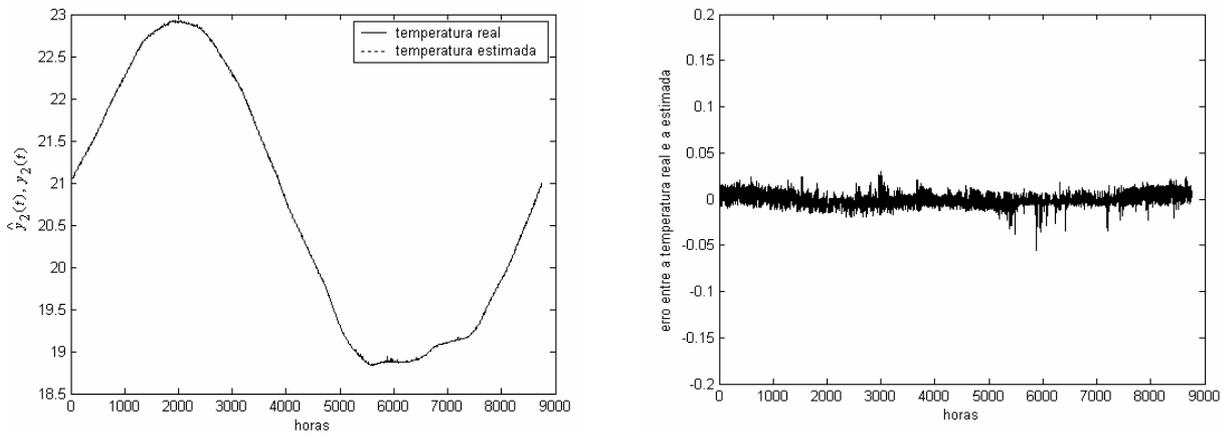


Figura 5 – Temperatura estimada a 2 m da superfície usando uma RN-RBF.

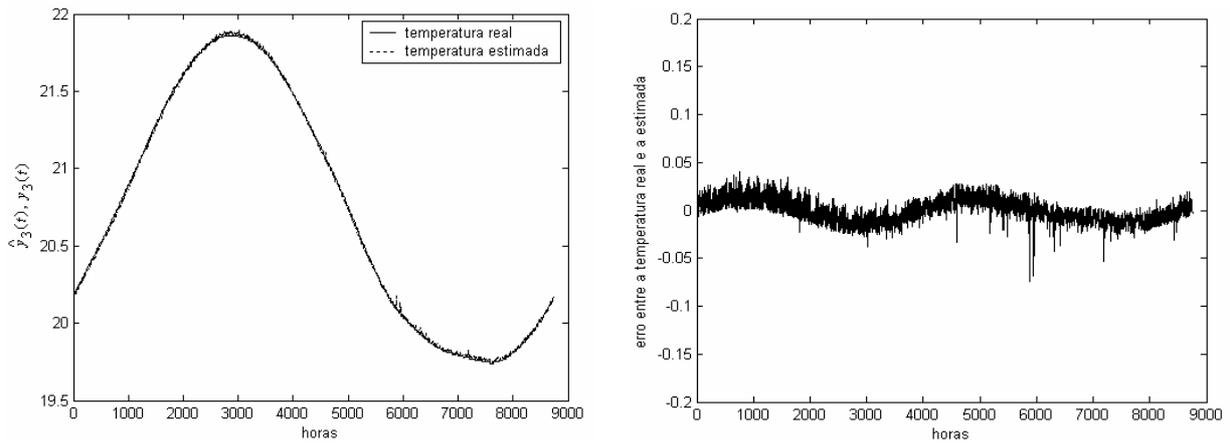


Figura 6 – Temperatura estimada a 3 m da superfície usando uma RN-RBF.

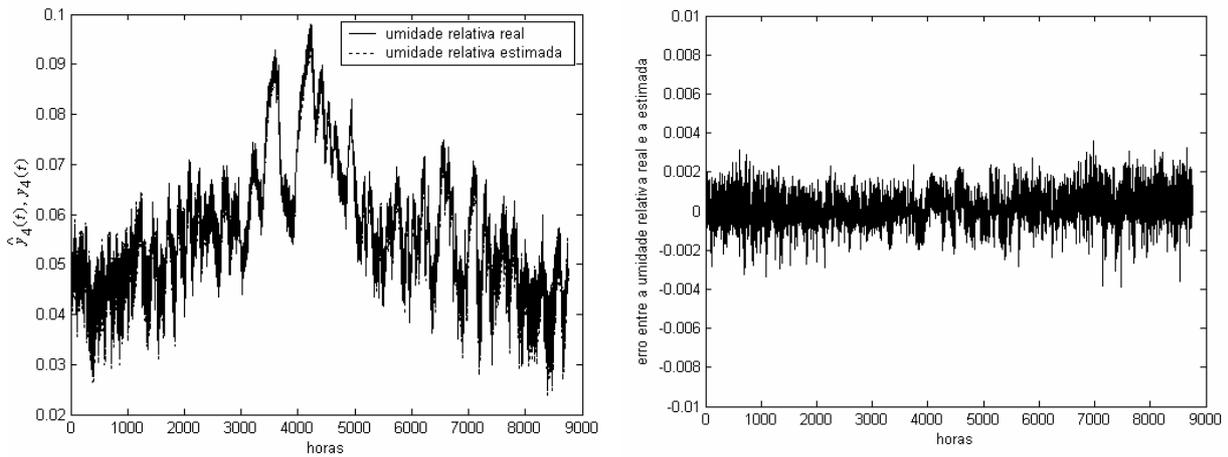


Figura 7 – Umidade relativa estimada na superfície (0 m) usando uma RN-RBF.

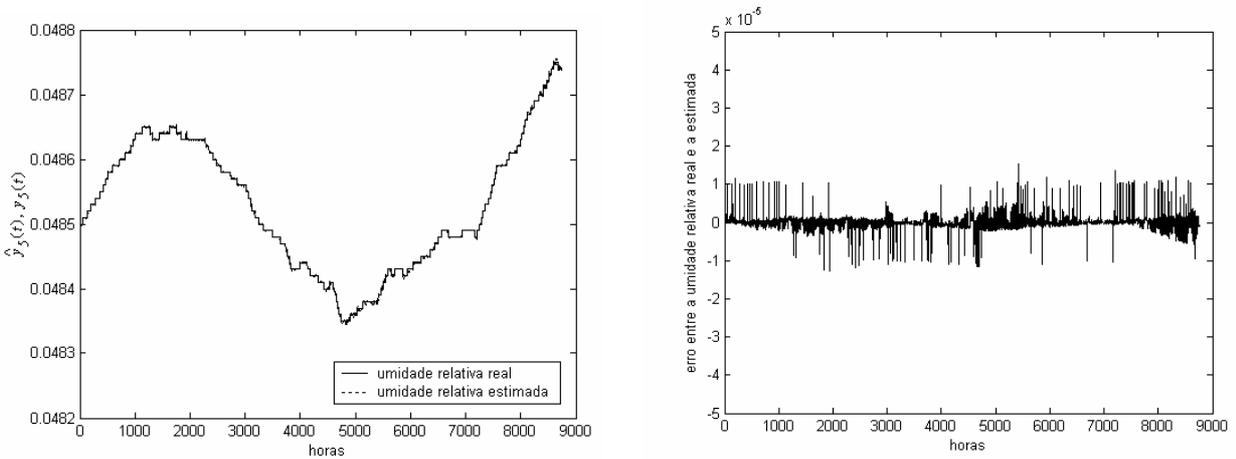


Figura 8 – Umidade relativa estimada a 1 m da superfície usando uma RN-RBF.

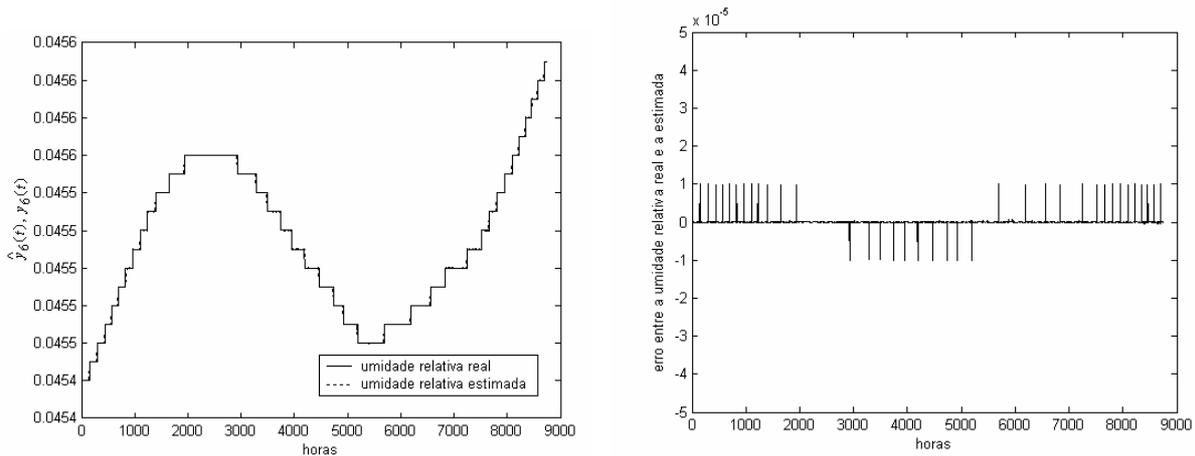


Figura 9 – Umidade relativa estimada a 2 m da superfície usando uma RN-RBF.

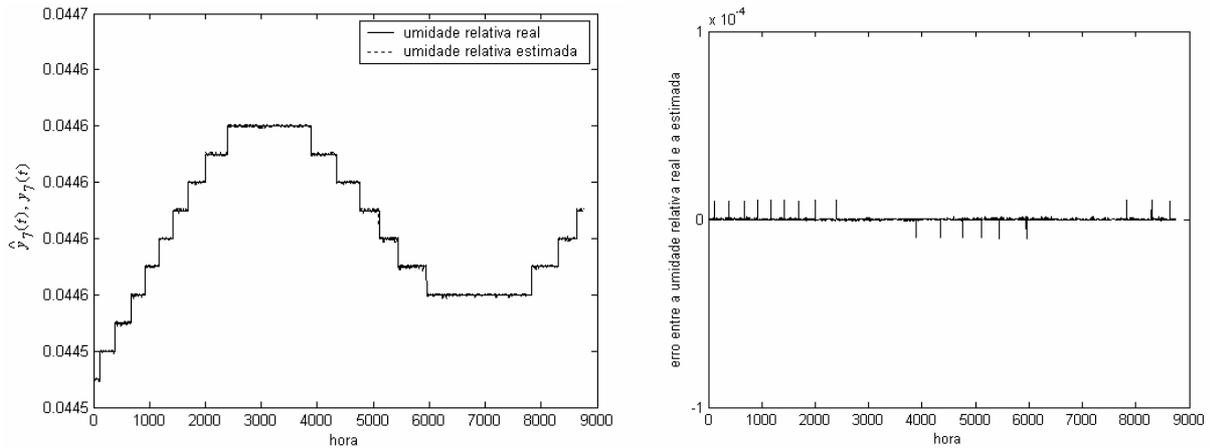


Figura 10 – Umidade relativa estimada a 3 m da superfície usando uma RN-RBF.

5. Conclusão e futura pesquisa

Este trabalho apresentou o projeto e aplicação de uma RN-RBF utilizando método de agrupamento Gath-Geva e pseudo-inversa para um estudo de caso para previsão (curtíssimo prazo) um passo à frente de perfis de temperatura e umidade do solo para a cidade de Curitiba.

A RN-RBF obteve resultados promissores em termos de desempenho (baseado no índice de desempenho R^2) na previsão do comportamento dinâmico de perfis de transferência de calor e umidade em solos. O aprendizado da RN-RBF é particularmente simples e rápido em relação à rede neural perceptron multicamadas (Haykin, 1996) muito utilizada em aplicações de identificação não-linear.

Um aspecto negativo da RN-RBF é a de que podem sofrer da “maldição” da dimensionalidade, pois quando a dimensão do vetor de entrada é aumentada a dimensionalidade dos centros das funções de base tem, geralmente, aumento exponencial para representar um sistema dinâmico não-linear adequadamente. Além disso, a adição de protótipos (funções de ativação) pode também ser requerida para tratar o aumento da complexidade causada por dimensões de entrada adicionais.

Uma dificuldade na configuração da RN-RBF para aplicações de identificação 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 levar a modelos matemáticos não apropriados devido ao grande número de entradas necessário.

Entretanto, se fazem necessários estudos mais aprofundados em relação a aspectos de: (i) conhecimento a priori de algumas características do processo a ser controlado, tais como ordem do modelo e atraso de transporte; (ii) configuração de algoritmos de poda (*pruning*) para a implementação da RN-RBF; e (iii) implementação de algoritmos de treinamento robustos tanto para buscas globais quanto locais com a implementação de algum procedimento de otimização para a identificação de perfis de transferência de calor e umidade em solos para previsões múltiplos passos à frente (previsões de médio e longo prazos).

6. Referências

- Abonyi, J., Babuska, R., Szeifert, F., 2002, "Modified Gath-Geva Fuzzy Clustering for Identification of Takagi-Sugeno Fuzzy Models", *IEEE Transactions on Systems, Man, and Cybernetics – Part B*, Vol. 32, No. 5, pp. 612-621, 2002.
- Abonyi, J., Feil, B., Nemeth, S., Arva, P., 2005, "Modified Gath-Geva Clustering for Fuzzy Segmentation of Multivariable Time-Series," *Fuzzy Sets and Systems*, Vol. 149, No. 1, pp. 39-56.
- Bezdek, J. C., Dunn, J. C., 1975, "Optimal Fuzzy Partitions: a Heuristic for Estimating the Parameters in a Mixture of Normal Distributions", *IEEE Transactions on Computers*, Vol. C-24, pp. 835-838.
- Chen, H., Liu, R. -W., 1992, "Adaptive Distributed Orthogonalization Processing for Principal Components Analysis", *Proceedings of International Conference on Acoustics, Speech and Signal Processing*, San Francisco, CA, USA, Vol. 2, pp. 293-296.
- Chen, S., Cowan, C., Grant, P., 1991, "Orthogonal Least Squares Learning Algorithm for Radial Basis Function Networks", *IEEE Transactions on Neural Networks*, Vol. 2, No. 2, pp. 302-309.
- Chen, Y., Chen, Z., 2000, "A Neural-network-based Experimental Technique for Determining z-transfer Function Coefficients of a Building Envelope", *Building and Environment*, Vol. 35, pp. 181-189.
- Crawley, D. B., Hand, J. W., Kummert, M., Griffith, B. T., 2005, "Contrasting the Capabilities of Building Energy Performance Simulation Programs", *Technical Report – version 1.0*, Department of Energy of USA, July.
- Cunningham, M. J., 2001, "Inferring Ventilation and Moisture Release Rates from Field Psychrometric Data only System Identification Techniques", *Building and Environment*, Vol. 36, pp. 129-138.
- Davies, M., Tindale, A., Litter, J., 1995, "Importance of Multi-dimensional Conductive Heat Flow in and around Buildings", *Building Serv. Engineering Research Technology*, Vol. 16, No. 2, pp. 83-90.
- Freire, R. Z., Santos, G. H., Mendes, N., 2003, "Software para a Simulação Tridimensional de Transferência de Calor e Umidade em Solos Porosos", *VII Encontro Nacional sobre Conforto no Ambiente Construído, ENCAC 2006*, Curitiba, PR.
- Gath, G., Geva, A. B., 1989, "Fuzzy Clustering for the Estimation of the Parameters of the Components of Mixtures of Normal Distributions", *Pattern Recognition Letters*, Vol. 9, No. 2, pp. 77-86.
- Gath, I., Geva, A. B., 1989a, "Unsupervised Optimal Fuzzy Clustering", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 11, No. 7, pp. 773-780.
- Guerra, F. A., 2006, *Análise de Métodos de Agrupamento para o Treinamento de Redes Neurais de Base Radial em Aplicações de Identificação de Sistemas*. Dissertação de mestrado, Pós-Graduação em Engenharia de Produção e Sistemas, Pontifícia Universidade Católica do Paraná, Curitiba, PR.
- Haghighat, F., Fazio, P., Zmeureanu, R. A., 1998, "A Systematic Approach for Derivation of Transfer Function Coefficients of Buildings from Experimental Data", *Energy and Buildings*, Vol. 12, pp. 101-111.
- Haykin, S., 1996, *Neural Networks*, 2nd edition, Prentice-Hall, Upper Saddle River, New Jersey.
- Leung, A. W. T., Tam, C. M., Liu, D. K., 2001, "Comparative Study of Artificial Neural Networks and Multiple Regression Analysis for Predicting Hoisting Times of Tower Cranes", *Building and Environment*, Vol. 36, pp. 457-467.
- Ljung, L., 1987, *System Identification - Theory for the User*. Prentice-Hall, Upper Saddle River, New Jersey.
- Lowe, D., 1989, "Adaptive Radial Basis Functions Nonlinearities and the Problem of Generalization", *Proceedings of 1st IEE International Conference on Artificial Neural Network*, London, UK, pp. 171-175.
- Mendes, N., Philippi, P. C., Lamberts, R., 2002, "A New Mathematical Method to Solve Highly Coupled Equations of Heat and Mass Transfer in Porous Media", *International Journal of Heat and Mass Transfer*, Vol. 45, pp. 509-518.
- Philip, J. R., D. A. de Vries, 1957, "Moisture Movement in Porous Media under Temperature Gradients", *Transactions of American Geophysical Union*, Vol. 38, No. 2, pp. 222-232.
- Santos, G. H., Mendes, N., 2003, "The SOLUM Program for Predicting Temperature Profiles in Soils: Mathematical Models and Boundary Conditions Analyses", *Proceedings of 8th International IBPSA Conference*, Eindhoven, Netherlands, pp. 1171-1176.
- Schaible, B., Xie, H., Lee, Y. C., 1997, "Fuzzy Logic Models for Ranking Process Effects", *IEEE Transactions on Fuzzy Systems*, Vol. 5, No. 4, pp. 545-556.

IDENTIFICATION OF THERMAL AND HUMIDITY CONTENT PROFILES IN SOILS USING NEURAL NETWORKS AND DATA CLUSTERING METHOD

Leandro dos Santos Coelho
Laboratório de Automação e Sistemas, LAS
Programa de Graduação em Engenharia de Produção e Sistemas, PPGEPS
Pontifícia Universidade Católica do Paraná – PUCPR
Rua Imaculada Conceição, 1155, CEP 80215-901, Curitiba, PR, Brasil
leandro.coelho@pucpr.br

Roberto Freire Zanetti, Gerson Henrique dos Santos e Nathan Mendes
Laboratório de Sistemas Térmicos, LST
Programa de Pós-Graduação em Engenharia Mecânica, PPGEM
Pontifícia Universidade Católica do Paraná – PUCPR
Rua Imaculada Conceição, 1155, CEP 80215-901, Curitiba, PR, Brasil
rozafre@terra.com.br; gerson.santos@pucpr.br; nathan.mendes@pucpr.br

Abstract

There is a wide variety of identification methods and model structures forms to choose for system nonlinear identification applications. Neural networks have proved to be versatile and useful nonlinear models for industrial processes. This paper presents a radial function neural network (RBF-NN) application using the Gath-Geva clustering method and pseudo-inverse to identification of heat transfer and humidity profiles in soils. The simulation results indicate the potentialities of the RBF-NNs learning for one step ahead identification of heat transfer and humidity profiles in soil.

Keywords: heat transfer and humidity in soil, artificial neural networks, data clustering, nonlinear identification.