

# APLICAÇÃO DAS REDES NEURAIS ARTIFICIAIS PARA SIMULAÇÃO DO RESFRIAMENTO DE SOJA EM SILO COM SISTEMA DE AERAÇÃO

**Fábio Ronei R. Padilha, Oleg Khatchaturian, Fabiane Avena de Oliveira**

Depto de Física, Estatística e Matemática, DeFEM

Departamento de Tecnologia - DeTEC

Universidade Regional do Noroeste do Estado do Rio Grande do Sul- UNIJUI

Rua São Francisco, 501 – Sede Acadêmica, 98700-000, Ijuí- RS- Brasil

E-mail: [roneipadilha@yahoo.com.br](mailto:roneipadilha@yahoo.com.br), [olegkha@unijui.tche.br](mailto:olegkha@unijui.tche.br),

[fabiane@unijui.tche.br](mailto:fabiane@unijui.tche.br).

O trabalho apresentado tem como objetivo desenvolver um modelo para simulação do estado térmico de produtos armazenados em silos com sistema de aeração sujeito à variação da temperatura do ar ambiente.

Foram obtidos experimentalmente as curvas de dinâmica de resfriamento de massa de soja em câmara experimental para várias seções de câmara com várias velocidades do ar.

A comparação destes dados com dados simulados pelos vários modelos (“reator homogêneo”, sistema de equações diferenciais parciais e método de generalização) é mostrada na Figura 1.

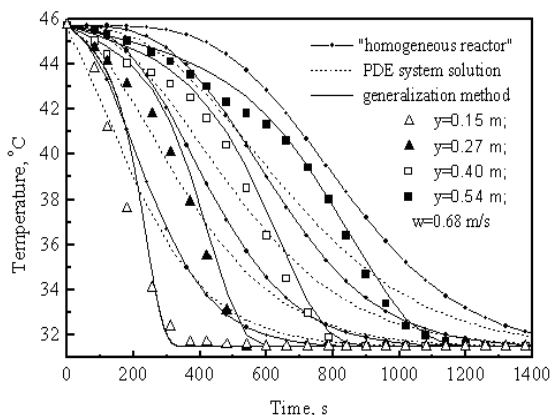


Figura 1: Simulação de resfriamento

Pode-se notar que mesmo o melhor método (generalização) tem diferença significativa com os dados experimentais. Para reduzir a discrepância entre dados experimentais e os simulados neste trabalho foram aplicadas Redes Neurais Artificiais (RNA), onde o esquema é mostrado na Figura 2.

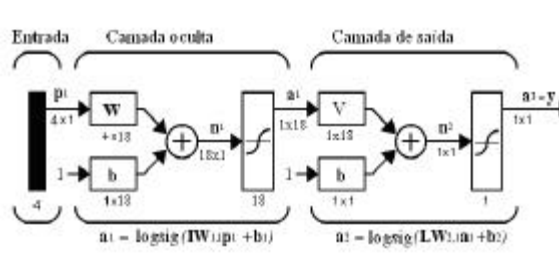


Figura 2: Arquitetura utilizada nas simulações

Foi usado o algoritmo *backpropagation – multilayer feedforward network* com RNA de várias arquiteturas. Como vetores de entrada foram usados os parâmetros iniciais que determinam a dinâmica de resfriamento (temperaturas iniciais do grão e do ar ambiente, a velocidade do ar, a distância entre a camada considerada e a seção inicial, o vetor dos tempos considerados). Como vetores de objetivo foram usados os dados experimentais (temperatura dos grãos em camada considerada para tempos correspondentes).

Foram variadas as funções de treinamento (gradient descent momentum and adaptive learning rate, gradients conjugados, etc.).

Na Figura 3 onde estão apresentados os dados experimentais e simulados pela RNA usada, temos uma boa coincidência entre os resultados.




Figura 3: Comparação entre dados experimentais e simulados com RNA

As simulações feitas permitiram escolher a arquitetura de RNA (o número de camadas e de neurônios necessários) com um bom desempenho.

## **Referências**

- [1] Fouseff, L.V., Fundamentals of neural networks: architectures, algorithms and applications. New Jersey, 1994.
- [2] Laesch, Claudio., Sari, Solange T., Redes Neurais Artificiais Fundamentos e Modelos. Ed da FURB, Blumenau 1996.
- [3] Hanselman, Duane., Littlefield., Matlab 6 Curso Completo. Trad. Claudia Sant'Ana Martins - UNICAMP. Ed. Prentice Hall. São Paulo – SP 2003.
- [4] Shalkoffn, Robert J., Artificial neural networks. McGaw-Hill, USA,1997.