

Simulação do Processo de Aeração da Massa de Grãos de Soja Através de uma Rede Neural

Jotair Elio Kwiatkowski Junior¹

Departamento de Matemática, DeMAT, UNICENTRO, Guarapuava, PR

Resumo. O presente trabalho analisa o método que melhor se ajusta através de uma rede neural para simular a dinâmica de resfriamento da massa de grãos de soja comparando com os dados experimentais. Este estudo mostrou que o método que melhor se ajustou a curva formada pelas temperaturas de resfriamento, foi o método de BFGS Quasi-Newton que obteve um erro de 10^{-2} em menos épocas do que os demais métodos. Outros métodos não convergiram nos mostrando que dependendo do comportamento da curva que estamos treinando ou ajustando um determinado método irá se destacar. Logo, esta análise foi de extrema importância para comparar os dados experimentais com o melhor treinamento da rede, sendo esta treinada com 2 camadas escondidas, tendo a primeira 3 neurônios e a segunda 4.

Palavras-chave. Simulação do Processo de Aeração da Massa de Grãos de Soja Através de uma Rede Neural.

1 Introdução

A aeração é a passagem forçada de ar através de uma massa de grãos armazenada, visando prevenir ou solucionar problemas de conservação do produto e secundariamente com o interesse de promover a secagem. A aeração é, atualmente, a técnica mais utilizada para melhorar as condições de secagem e armazenamento. Dentre as várias utilidades da aeração as principais são: Resfriamento e a manutenção da massa de grãos a uma temperatura suficientemente baixa, para assegurar uma boa conservação; secundariamente o interesse pode ser a secagem; Prevenir o aquecimento e o umedecimento da massa de grãos; Promover a remoção de odores na massa de grãos e inibir as atividades de insetos e o desenvolvimento da microflora, evitando o aparecimento de fungos que deterioram o produto. Os conjuntos que compõem um sistema de aeração visam, principalmente, a distribuição uniforme da movimentação do ar através da massa de grãos, de tal forma que todas as zonas da massa aeradas sejam feita de forma homogênea. Por sua vez, redes neurais (mais propriamente, redes neuronais artificiais) são sistemas computacionais estruturados numa aproximação à computação baseada em ligações. Nós simplesmente (neurônios, processadores ou unidades) são interligados para formar uma rede de nós, daí o termo rede neuronal. A inspiração original para essa técnica advém do exame das estruturas do cérebro, em particular do exame de neurônios. Assim, definida à aeração

¹jotairkw@yahoo.com.br

e redes neurais analisaremos o comportamento de vários métodos através de uma rede neural devidamente treinada comparando os dados experimentais com o comportamento da rede treinada para verificar qual método se ajusta melhor com as temperaturas da massa de grãos dos experimentos.

2 Metodologia

Apresentaremos, nesta secção os dados experimentais utilizados para a comparação com a simulação e os métodos utilizados para a comparação com os dados experimentais.

2.1 Dados Utilizados para Comparação com Simulação

Segundo OLIVEIRA et al. (2007), estes dados foram obtidos no laboratório de medidas físicas e modelagem matemática da Universidade Regional do Noroeste do Rio Grande do Sul (UNIJUI), em um pequeno "silo" composto por um tubo de PVC com isolamento térmico nas laterais, altura de 1,0 m e diâmetro de 0,15 m. Para realização dos experimentos os grãos de soja com teor de água médio de 12% (b.u) foram previamente selecionados, limpos e aquecidos em estufa até temperatura aproximada de 52° C (temperatura inicial), durante aproximadamente 8 h, suficiente para uniformizar a temperatura em toda a massa de grãos. O resfriamento dos grãos aquecidos foi realizado por meio da ventilação de uma camada de grãos de soja de 0,60 m de altura pelo ar ambiente, por um ventilador centrífugo, acionado por motor elétrico com 3/4 cv. Esse ventilador estava ligado a um inversor de frequência que controlava a velocidade do ar. A temperatura dos grãos foi medida por termopares modelo MTK - tipo K, inseridos dentro da massa de grãos ao longo do tubo, nas seguintes seções da coluna de grãos: $y = 0,15$ m; $y = 0,27$ m; $y = 0,40$ m; $y = 0,54$ m e ligados a uma placa de aquisição de dados A/D do tipo LR 7017, que permitia realizar até dez leituras por segundo. Na entrada da câmara, foi medida a temperatura do ar de entrada utilizado para aeração (temperatura ambiente). Segue esquema da bancada utilizada no experimento (Fig. 1).




Figura 1: Esquema da bancada usada na aquisição dos dados experimentais.

2.2 Métodos de Solução Utilizados nas Redes Neurais

Os métodos utilizados foram de Levenberg-Marquardt, BFGS Quasi-Newton, Resilient Backpropagation, Scaled Conjugate Gradient, Conjugate Gradient with Powell/Beale Restarts, Fletcher-Powell Conjugate Gradient, Polak-Ribire Conjugate Gradient, One Step Secant, Variable Learning Rate Gradient Descent, Gradient Descent with Momentum e Gradient Descent. Devido ao fato do método de Levenberg-Marquardt ser o que melhor se enquadra no ajuste de uma curva, que conseqüentemente é à fonte do nosso estudo das temperaturas na massa de grãos de soja. Analisaremos a melhor estrutura para esta rede com este método para posteriormente comparar com os demais.

3 Resultados

Como citamos na seção anterior analisaremos primeiramente o método de Levenberg-Marquardt para posteriormente comparar com os demais métodos. Para estes métodos encontramos depois de um treinamento de 20 simulações da rede, os números de camadas e neurônios que melhor se ajustou aos dados experimentais, ou seja, com o menor erro possível tomando os devidos cuidados para que a rede não decora-se os padrões de treinamento. Assim, encontramos o melhor ajuste com duas camadas escondidas, sendo a primeira com 3 neurônios e a segunda com 4 neurônios. Os dados foram atribuídos na rede por meio de um vetor padrão o que representa o tempo que foram coletadas as temperaturas a cada 60s, e uma matriz com as temperaturas coletas nestes instantes de tempo nas respectivas alturas dos termopares da massa de grãos, em 0,15m, 0,27m, 0,40m e 0,54m que sera nosso alvo. Os testes foram feitos com um vetor padrão de 30 em 30s e seus respectivos alvos nas alturas estudadas. A Fig. 2 representa a janela de comando de treinamento da rede neural, neste caso utilizando o método de Levenberg-Marquardt.

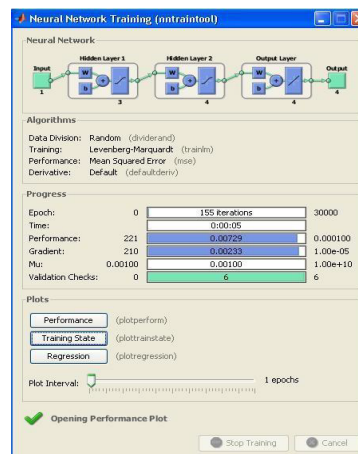


Figura 2: Estrutura da janela de comando do MATLAB que apresenta o treinamento.

Nas Figuras (3b, 4b, 5b, 6b, 7b, 8b, 9b, 10b, 11b, 12b e 13b), comparando-se os dados experimentais de Oliveira (2007) com a simulação dos métodos. Que representam a

dinâmica de resfriamento da massa de grãos de soja. Onde estão discriminados nos gráficos a simulação do método (tracejado), dados experimentais (valores discretos), temperatura do ar (linha), com $y = 0.15, 0.27, 0.40$ e 0.54m e velocidade do ar = 0.23 m/s .

Já nas Figuras (3a, 4a, 5a, 6a, 7a, 8a, 9a, 10a, 11a, 12a e 13a) representam a performance de treinamento de cada respectivo método avaliado, com seu erro relativo. A curva de treinamento dos métodos Levenberg-Marquardt, BFGS Quasi-Newton, Resilient Backpropagation, Scaled Conjugate Gradient, Conjugate Gradient with Powell/Beale Restarts, Fletcher-Powell Conjugate Gradient, Polak-Ribire Conjugate Gradient, One Step Secant, Variable Learning Rate Gradient Descent, Gradient Descent with Momentum e Gradient Descent, foram, apresentados em tais figuras tiveram épocas, respectivamente, dos métodos: 149, 56, 101, 141, 44, 111, 41, 81, 93, 0 e 0. A seguir temos as referidas figuras de performance de treinamento e da comparação dos dados experimentais com os simulados.

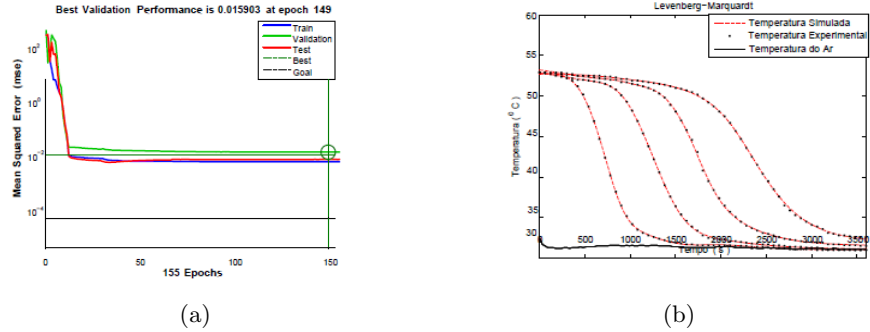


Figura 3: (a) Performance de treinamento do método de Laverberg-Marquardt. (b) Comparação da simulação do método de Leverberg-Marquardt com os dados experimentais.

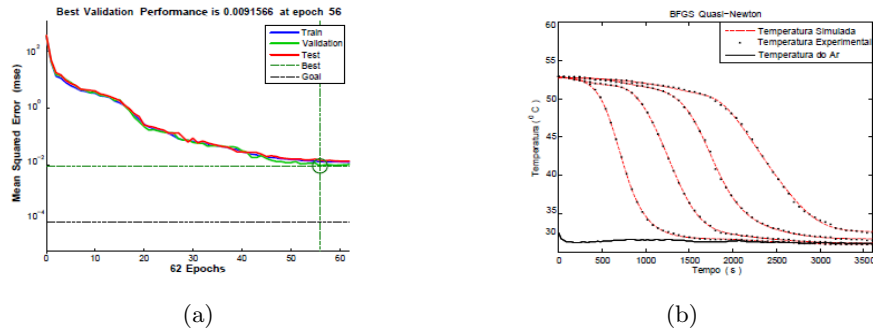


Figura 4: (a) Performance de treinamento do método de BFGS Quasi-Newton. (b) Comparação da simulação do método de BFGS Quasi-Newton com os dados experimentais.

Verificamos nas figuras que representam a performance de treinamento, os métodos que melhor descreveram o comportamento das temperaturas dos termopares foram os métodos de Lavenberg-Marquardt, BFGS Quasi-Newton e Scaled Conjugate Gradient, com seus respectivos erros 10^{-2} , 10^{-2} e 10^{-1} . Entre estes métodos o melhor foi o de

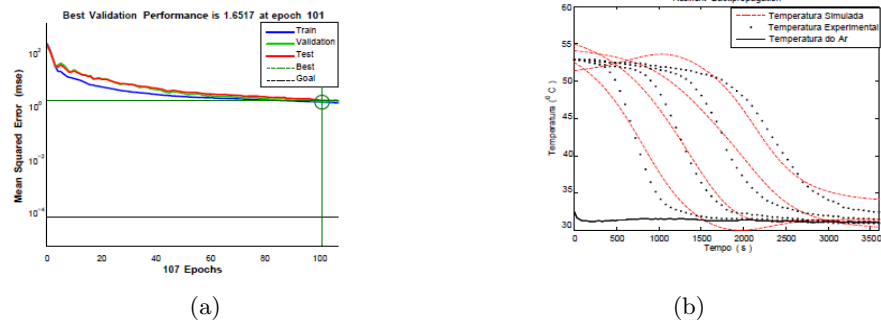


Figura 5: (a) Performance de treinamento do método de Resilient Backpropagation. (b) Comparação da simulação do método de Resilient Backpropagation com os dados experimentais.

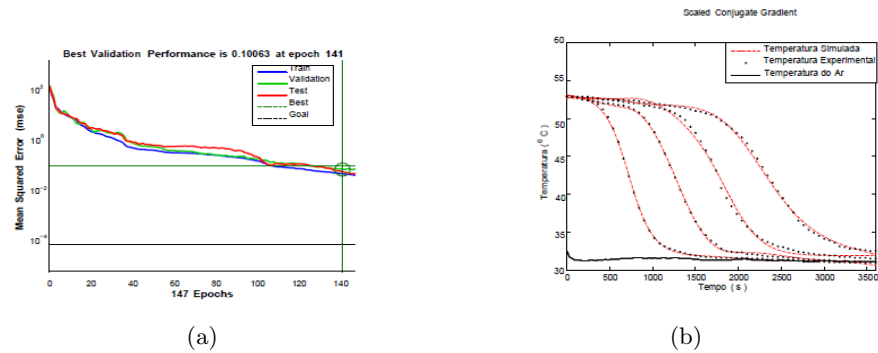


Figura 6: (a) Performance de treinamento do método de Scaled Conjugate Gradient. (b) Comparação da simulação do método de Scaled Conjugate Gradient com os dados experimentais.

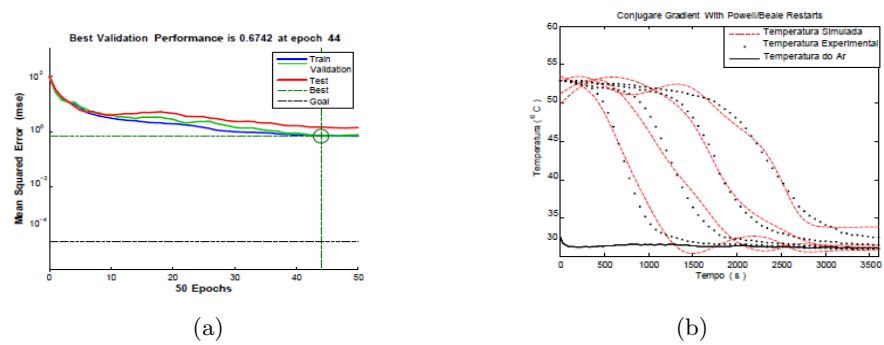


Figura 7: (a) Performance de treinamento do método de Conjugate Gradient with Powell/Beale Restarts. (b) Comparação da simulação do método de Conjugate Gradient with Powell/Beale Restarts com os dados experimentais.

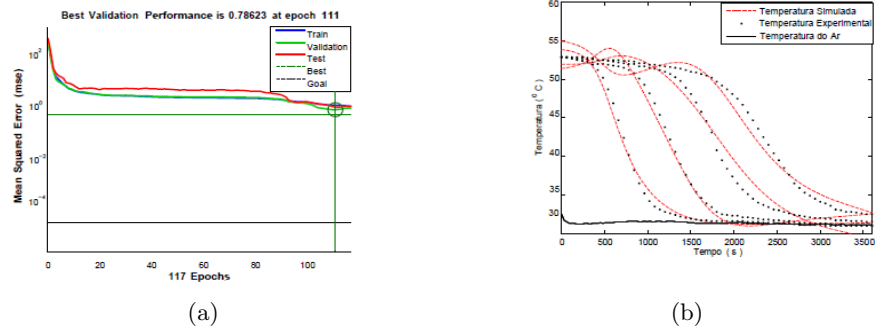


Figura 8: (a) Performace de treinamento do método de Fletcher-Powell Conjugate Gradient. (b) Comparação da simulação do método de Fletcher-Powell Conjugate Gradient com os dados experimentais.

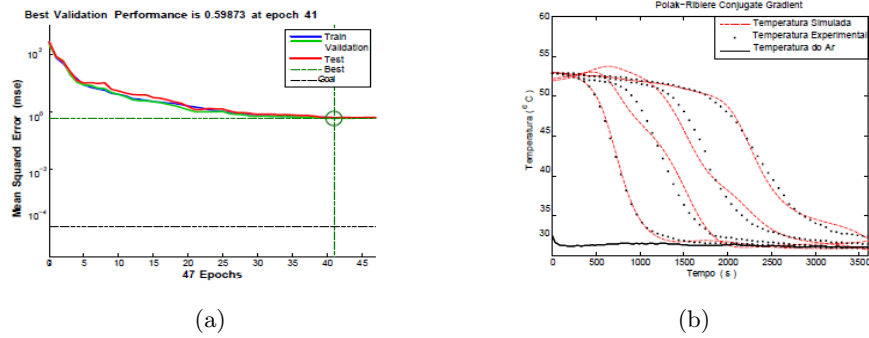


Figura 9: (a) Performace de treinamento do método de Polak-Ribire Conjugate Gradient. (b) Comparação da simulação do método de Polak-Ribire Conjugate Gradient com os dados experimentais.

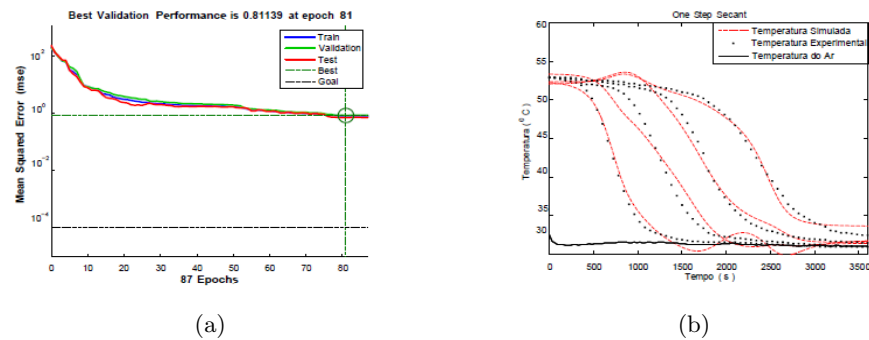




Figura 10: (a) Performace de treinamento do método de One Step Secant. (b) Comparação da simulação do método de One Step Secant com os dados experimentais.




(a)




(b)

Figura 11: (a) Performace de treinamento do método de Variable Learning Rate Gradient Descent. (b) Comparação da simulação do método de Variable Learning Rate Gradient Descent com os dados experimentais.




(a)




(b)

Figura 12: (a) Performace de treinamento do método de Gradient Descent with Momentum. (b) Comparação da simulação do método de Gradient Descent with Momentum com os dados experimentais.



(a)



(b)

Figura 13: (a) Performace de treinamento do método de Gradient Descent. (b) Comparação da simulação do método de Gradient Descent com os dados experimentais.

BFGS Quasi-Newton que apresentou o mesmo erro que o de Levenberg-Marquardt, mas em menos épocas. Os métodos que divergiram e não mostrou o comportamento da curva da dinâmica de resfriamento da massa de grãos, foram os métodos Gradient Descent with Momentum e Gradient Descent. Os demais métodos podem ser melhorados visando aperfeiçoar as camadas internas da rede e seus neurônios. Verificando as figuras que representam o comportamento dos dados experimentais e a temperatura simulada, podemos notas o comportamento de cada método e sua aproximação com os dados experimentais, comparados com seu erro relativo.

4 Conclusões

Verificamos que para este problema da dinâmica de resfriamento da massa de grãos de soja o método que melhor descreveu o comportamento da temperatura em cada termopar estudado foi o método de BFGS Quasi-Newton, pois este apresentou um erro de 10^{-2} em menos épocas que o segundo melhor método de Lavenberg-Marquardt também com o mesmo erro. Os dois últimos métodos apresentados nas figuras não obtiveram sucesso pois os mesmos divergem. Os demais métodos devem ser analisados com mais cautela, pois modificando as camadas e neurônios pode haver uma significativa melhora no comportamento da curva de resfriamento. Assim, notamos que dependendo do problema que se é posto teremos que verificar e analisar com diferentes camadas internas e neurônios o comportamento do mesmo.

Referências

- [1] J. E. Kwiatkowski Jr., O. Khatchatourian, A. Bihain, A., Simulação e controle do sistema de aeração da massa de grãos de soja. XXXIII Congresso Nacional de Matemática Aplicada e Computacional, Águas de Lindoia-SP, (2010).
- [2] J.E. Kwiatkowski Jr., Simulação e controle do sistema de aeração da massa de grãos de soja. Dissertação de mestrado, cap. 3, Editora Universitária, UNIJUI, (2011).
- [3] F. A. Oliveira, O. A. Khatchatourian, Estado térmico de produtos armazenados em silos com sistema de aeração: Estudo teórico e experimental. Engenharia Agrícola, V. 27, n. 1, p.247-258, (2007).
- [4] X. Zhang, Time series analysis and prediction by neural networks. Optimization Methods ans Software, v. 4, págs. 151-170, (1994).