



Acta Scientiarum. Technology

ISSN: 1806-2563

eduem@uem.br

Universidade Estadual de Maringá
Brasil

Klassen, Túlio; Dias Martins, Tiago; Cardozo Filho, Lucio; da Silva, Edson Antonio
Modelagem do sistema de resfriamento por imersão de carcaças de frangos utilizando redes neurais
artificiais

Acta Scientiarum. Technology, vol. 31, núm. 2, 2009, pp. 201-205

Universidade Estadual de Maringá
Maringá, Brasil

Disponível em: <http://www.redalyc.org/articulo.oa?id=303226524011>

- Como citar este artigo
- Número completo
- Mais artigos
- Home da revista no Redalyc

redalyc.org

Sistema de Informação Científica
Rede de Revistas Científicas da América Latina, Caribe, Espanha e Portugal
Projeto acadêmico sem fins lucrativos desenvolvido no âmbito da iniciativa Acesso Aberto

Modelagem do sistema de resfriamento por imersão de carcaças de frangos utilizando redes neurais artificiais

Túlio Klassen^{1*}, Tiago Dias Martins¹, Lucio Cardozo Filho² e Edson Antonio da Silva¹

¹Centro de Engenharias e Ciências Exatas, Universidade Estadual do Oeste do Paraná, Rua da Faculdade, 645, 85903-000, Jardim La Salle, Toledo, Paraná, Brasil. ²Departamento de Engenharia Química, Universidade Estadual de Maringá, Maringá, Paraná, Brasil. *Autor para correspondência. E-mail: tulio_klassen@onda.com.br

RESUMO. A modelagem matemática fenomenológica do processo de resfriamento de carcaças de frango em *chillers* é complexa pela quantidade de variáveis que interferem no processo, além de tratar de um problema que envolve transferência de calor e de massa em regime transiente. Uma alternativa para modelar este tipo de sistema é o emprego de Redes Neurais Artificiais. Neste trabalho foram investigadas diversas estruturas de redes com uma camada intermediária para modelar o processo de resfriamento de frangos. Foram testadas diferentes arquiteturas alterando os números de neurônios das camadas de entrada e intermediária. Foram utilizados dados coletados na empresa Sadia-Toledo, Estado do Paraná, para treinamento e validação das redes. As variáveis de entrada da rede eram: massa da carcaça, temperatura antes do resfriamento, temperatura da camisa de propilenoglicol, vazão de água em cada módulo, tempo de residência e temperatura da água de renovação; a temperatura do frango na saída do último tanque de resfriamento era a variável de saída. Os resultados obtidos mostraram que as redes representam apropriadamente o processo e que a rede com estrutura 8-24-1 foi a que melhor modelou o sistema investigado.

Palavras-chave: resfriamento, *chillers*, redes neurais, frango.

ABSTRACT. Modeling of the poultry carcass immersion chilling system using artificial neural networks. The process of cooling chicken carcasses by immersing them in mixture of cold water and ice (*chillers*) is complex. It is very difficult to represent it by a transport phenomenon model. In this work, artificial neural networks were used with an intermediary layer in the description and modeling of the cooling process of chickens. Different architectures of the neural network were tested, altering the numbers of input and hidden units. Data supplied by the Sadia-Toledo Company were used for training and validation of the neural networks. The input variables selected for the model were the following: carcass weight, initial temperature, propylene glycol temperature with external circulation, water flow rate of water in each tank, renewal water cooling time and temperature, and as output variable the temperature of the chicken when exiting the chiller. The results obtained showed that the network with 8 neurons in the input layer and 24 in the hidden layer best represented the investigated system.

Key words: cooling, chillers, neural networks, chicken.

Introdução

O processamento térmico de produtos alimentícios é uma técnica de preservação conhecida desde o início do século XIX e, na última década, diversos estudos foram realizados com objetivo de otimizar a qualidade deste processo (MITTAL; ZHANG, 2002).

O resfriamento de carne de frango é uma das etapas mais importantes no processamento da carne, pois a redução da temperatura, além de conter o crescimento microbiano, influencia os principais indicadores de qualidade da carne, tais como: sabor, aparência e textura (SAVELL et al., 2005).

Entre os métodos de resfriamento industrial disponíveis, destacam-se o *air-chiller* (túneis de ar seco refrigerado) e *chiller* (tanques de imersão em água). No Brasil, não se utiliza o *air-chiller*, pois no processo há perda de massa da carcaça na faixa de 3-4%. Nos *chillers*, as carcaças são resfriadas ao passarem por uma série de tanques. Assim, o processo de resfriamento se dá pelo contato direto das carcaças com água e gelo.

Os *chillers* são equipamentos que apresentam geometria semicilíndrica, dotados de um helicóide interno que se move lentamente, provocando o deslocamento das carcaças, conforme representado na Figura 1.

A fim de acelerar a troca térmica entre o frango e a água, os *chillers* possuem camisas onde ocorre a circulação de uma solução de propilenoglicol em baixa temperatura e, ainda, é adicionado gelo em escamas em diversos pontos ao longo dos tanques. Uma vez que a densidade das carcaças de frango é menor que a unidade elas flutuam e, pelo deslocamento do helicóide, tendem a acumular em um único lado dos *chillers*, oposto ao qual se encontra a entrada da água de renovação. Isso faz surgir canais preferenciais de fluxo, o que diminui a troca térmica. Assim, para minimizar esse efeito, provoca-se uma intensa movimentação da água borbulhando-se ar em pequenos furos na base do tanque.




Figura 1. Representação do corte transversal de um *chiller*.

No processo de abate de frangos, cada país possui legislação específica e tem uma série de parâmetros que devem ser cumpridos, entre os quais: parâmetros de temperatura. No Brasil, os parâmetros do processo são regulamentados pela Portaria 210 do MAPA, de 1998 (BRASIL, 1998), que define os limites de temperatura máxima da água na entrada e na saída, vazões mínimas, número de tanques etc. Para o caso da temperatura final da carcaça, a Portaria estabelece um máximo de 7°C. Na União Europeia, a legislação é mais rigorosa e estabelece que a temperatura máxima final da carne seja igual a 4°C, antes de seu corte e transporte.

Entre os fatores que interferem no processo de resfriamento de frangos, podem ser citados: (i)-massa inicial do frango, (ii)-velocidade do abate, (iii)-temperatura inicial do frango, (iv)-tempo de retenção nos *chillers*, total e por módulo, (v)-vazão da água de renovação em cada módulo, (vi)-temperatura da água de renovação, (vii)-vazão do propilenoglicol, (viii)-temperatura do propilenoglicol, (ix)-eficiência do borbulhamento, (x)-massa de gelo adicionada, total e por módulo, (xi)-ponto de adição do gelo, (xii)-temperatura do gelo. Adicionalmente, as variáveis ambientais, como temperatura e umidade do ar, variáveis construtivas,

tais como espessuras e materiais de isolamento, também devem ser levadas em consideração.

Desse modo, a formulação matemática do processo de resfriamento de carcaças de frango por imersão é complexa, pois depende de muitas variáveis e envolve transferência de calor e massa em regime transiente. Além disso, a predição de propriedades específicas da carne é particularmente difícil, pela complexa mistura dos componentes químicos que o constituem (SWEAT, 1995). Por esses fatores, os modelos completos gerados são de difícil solução exata e, por outro lado, se simplificados, as equações podem perder a representatividade, dificultando qualquer tentativa de simulação.

Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA's) são um algoritmo matemático, baseado na estrutura de um neurônio biológico, que possui a capacidade de relacionar parâmetros de entrada (variáveis independentes) e saída (variáveis dependentes) aprendendo com exemplos fornecidos (BAUGHMAN; LIU, 1995), sem requerer conhecimento algum acerca da relação entre as variáveis que interferem no processo em questão. Por esse motivo, são conhecidas como aproximadores universais de funções (SILVA et al., 2003).

As RNA's são formadas por vários elementos, os neurônios artificiais, que procuram simular a forma, o comportamento e as funções de um neurônio biológico. O funcionamento de um neurônio artificial é semelhante ao de um neurônio biológico: possui entradas e saídas que são conectadas à entrada do neurônio subsequente (Figura 2). Às variáveis de entradas são associados os pesos sinápticos que as modificam, ponderando sua importância para a unidade de processamento em questão. Esses sinais ponderados são somados, formando o coeficiente de ativação, que é representado pela equação:

$$\alpha_{k_i} = \sum_{j=1}^n w_{i,j} \cdot x_j \quad (1)$$

em que:

α_{k_i} é valor de ativação do neurônio i da camada k ;

$w_{i,j}$ é peso da variável j em relação ao neurônio i ;

x_j é a variável de alimentação no neurônio e n é o número de alimentações do neurônio.

A saída do neurônio é calculada por meio de uma função de ativação que pode assumir diversas formas. Recomenda-se a utilização de funções

diferenciáveis e que apresentem uma não-linearidade suave. Destacam-se as funções tangente hiperbólica, logística etc (HAYKIN, 2005).




Figura 2. Constituintes do neurônio artificial.

As RNA's vêm sendo aplicadas em diversas áreas da Ciência, entre elas: estudo de equilíbrio de dados binários de adsorção, resolução de equações diferenciais, interpolação de dados de GPS, estudo de equilíbrio líquido-líquido-vapor, otimização e controle de processos, estudo de inibição enzimática, etc (FAGUNDES-KLEN et al., 2007; SOUZA et al., 2006; ANTONELLI; NEITZEL, 1999; CORAZZA et al., 2005; SILVA et al., 2003). Além disso, têm-se mostrado de fácil implementação, robustas no tratamento de dados com ruídos e eficientes, especialmente nos problemas em que não se tem uma formulação analítica adequada ou não se tem um conhecimento explícito acessível sobre eles, ou ainda, naqueles em que os dados estão 'contaminados' por ruído ou o próprio problema modifica-se com o tempo (BRAGA et al., 2000).

O emprego de uma RNA depende da habilidade em adaptá-la ao problema considerado por meio de mudanças nos pesos sinápticos, o que corresponde à etapa de treinamento da rede, de modo a aumentar sua eficiência (MITTAL; ZHANG, 2000).

Para o treinamento de uma rede neural é necessário um conjunto de dados suficiente para garantir que a rede realmente aprenda as relações entre as variáveis e não apenas 'decore exemplos'. Não existe uma regra que estabeleça quantos pontos são necessários. Espera-se apenas que quanto mais pontos forem usados, menor será o erro na validação.

As RNA's têm sido utilizadas com sucesso em problemas de processamento de alimentos. Uma das principais aplicações é a predição do tempo de congelamento de produtos alimentícios (MITTAL; ZHANG, 2000, 2001).

Desse modo, o objetivo principal deste trabalho

foi obter um modelo simples para prever a temperatura das carcaças de frango na saída dos *chillers* de resfriamento.

Material e métodos

O processo de resfriamento de frango estudado é um módulo industrial constituído de três *chillers* em série. Nesse sistema, o segundo e o terceiro *chillers* possuem camisas com circulação do propilenoglicol e adição de gelo, e todos possuem borbulhamento de ar.

Para a modelagem do sistema de resfriamento, utilizou-se RNA's com uma camada intermediária. As variáveis independentes selecionadas que constituíram a alimentação da rede foram as seguintes: massa da carcaça, temperatura da carcaça antes do *chiller*, temperatura do propilenoglicol, temperatura da água de renovação, vazão do *chiller* lavador, vazão do pré-*chiller*, vazão do *chiller* e tempo de resfriamento. Todos os dados foram coletados na empresa Sadia-Toledo, Estado do Paraná.

A vazão de propilenoglicol, a eficiência do borbulhamento, a massa de gelo adicionada e sua respectiva temperatura, assim como o ponto de adição, permaneceram constantes e, por este motivo, foram eliminados. Variáveis ambientais e construtivas não foram levadas em conta e aparecem apenas como ruídos. A variável de saída da rede era a temperatura na saída do terceiro *chiller*.

Pela dinâmica do processo foram coletados 20 vetores ao dia, sendo 300 vetores no treinamento (15 dias) e 136 vetores para a validação. Cada vetor continha informações referentes às nove variáveis selecionadas. Todas as variáveis de entrada e saída da rede foram normalizadas de modo a garantir que seus valores estivessem na faixa de 0 e 1, de acordo com a equação:

$$X_{i,NORMALIZADO} = 0.8 \left(\frac{X_i - X_{i,\min}}{X_{i,\max} - X_{i,\min}} \right) + 0.1 \quad (2)$$

em que:

X_i é a variável i obtida experimentalmente;

os índices *mín* e *máx* indicam valor mínimo e máximo, respectivamente.

Foram testadas diferentes arquiteturas de redes alterando os números de neurônios das camadas de entrada e intermediária. Para o treinamento das RNA's, foi desenvolvido um programa computacional em linguagem Fortran. Para a determinação dos pesos dos neurônios, foram utilizadas: a função de ativação tangente hiperbólica (nas camadas de entrada e intermediária), a função linear (na camada de saída da rede) e método

Simplex de Nelder e Mead (1965) para minimizar a função-objetivo:

$$f_{\text{erro}} = \sum_{i=1}^n (y_{\text{rede},i} - y_{\text{real},i})^2 \quad (3)$$

em que:

$y_{\text{rede},i}$ é a temperatura da carcaça na saída do *chiller* calculada pela rede no ponto i ;

$y_{\text{real},i}$ é a temperatura da carcaça na saída do *chiller* obtida experimentalmente no ponto i ;

n é número de vetores de treinamento.

O critério de convergência adotado foi de 1.10^{-12} . Todas as simulações foram realizadas utilizando um computador com processador Athlon XP com *clock* de 1,8 GHz e 512 MB de memória RAM.

Resultados e discussão

O objetivo principal deste trabalho era modelar o processo de resfriamento de carcaças de frango em tanques de imersão. Para isso, foram testadas diversas arquiteturas de redes neurais artificiais a fim de se obter um modelo satisfatório. A quantidade de neurônios em cada camada foi variada buscando o número que apresentasse menor erro de previsão e que tivesse a maior velocidade de convergência.

Os vetores de treinamento foram, então, alimentados ao sistema, e as rotinas de otimização determinaram os pesos sinápticos adequados. Observou-se que, com o aumento da complexidade da rede, um número maior de iterações foi necessário para a convergência. Além disso, esse número é linearmente proporcional ao número de parâmetros a serem ajustados, o que é um resultado esperado tendo em vista o funcionamento do método de otimização utilizado. A Tabela 1 apresenta as estruturas investigadas, o número de iterações, o número de parâmetros e os valores dos erros médios para cada estrutura.

Tabela 1. Arquiteturas investigadas, número de parâmetros de cada estrutura e iterações para a convergência de cada rede e erro médio do treinamento.

Estrutura	Número de Parâmetros	Iterações	Erro Médio no Treinamento
2-8-1	24	44000	9,74%
4-8-1	72	112000	8,16%
8-8-1	136	313000	7,83%
4-4-1	52	50000	8,89%
4-16-1	112	252000	7,17%
4-24-1	152	686000	5,09%
8-24-1	280	1674000	4,16%

Pela Tabela 1, verifica-se que a estrutura de rede que continha apenas 24 parâmetros já representava o

processo de resfriamento de frangos de forma adequada. Tendo em vista que um modelo fenomenológico que possuísse a capacidade de relacionar as oito variáveis independentes selecionadas seria um modelo extremamente complexo, um erro médio de 9,74% no ajuste é bastante satisfatório.

Por outro lado, a configuração de rede que melhor representou o processo de resfriamento em questão continha oito neurônios na camada de entrada e 24 na camada intermediária, apresentando um erro médio de 4,16% na etapa de treinamento. Por esse motivo, a etapa de validação do modelo foi realizada com essa estrutura. A eficiência do treinamento da estrutura 8-24-1 pode ser visualizada na Figura 3, a qual compara os resultados calculados pelas redes em relação à temperatura experimental.

Na Figura 3, observam-se poucas anomalias ou grandes erros, indicando que os valores coletados tinham pouco ruído.




Figura 3. Resultado do Treinamento da RNA 8-24-1.

Da mesma maneira que no treinamento, o comportamento encontrado na validação ficou muito próximo do real, comprovando que a rede realmente aprendeu como o sistema de resfriamento funciona. Enquanto o erro médio no treinamento ficou em 4,16%, na validação este valor foi ainda menor, de apenas 3,52%. Além disso, pelos resultados apresentados na Figura 4, em que os valores da temperatura calculada pela RNA na etapa de validação e os valores experimentais foram comparados, observa-se pouca discrepância entre os valores experimentais e o previsto pelo modelo.

De maneira geral, os resultados obtidos nos treinamentos e na validação das redes indicaram que as RNA's podem ser utilizadas para representar

processos complexos como o processo de resfriamento de frango em *chillers*.




Figura 4. Resultado da validação da RNA 8-24-1.

Conclusão

Neste trabalho foi empregada a técnica de Redes Neurais Artificiais para prever a temperatura final de carcaças de frango no processo de resfriamento. A estrutura das RNA's investigada apresentava apenas uma camada intermediária. Os resultados obtidos indicaram que mesmo a RNA mais simples já ajustava adequadamente os dados experimentais. Além disso, a rede neural com oito neurônios na camada de entrada e 24 na camada intermediária foi a que melhor representou o sistema investigado, apresentando erros médios de 4,16% e 3,52%, para o treinamento e a validação, respectivamente. As redes neurais mostraram-se uma ferramenta eficiente na modelagem do sistema investigado.

Referências

- ANTONELLI, G. C.; NEITZEL, I. Controle de Processos com Redes Neurais Artificiais. **Revista Tecnológica**, v. 8, p. 41-53, 1999.
- BAUGHMAN, D. R.; LIU, T. A. **Neural networks in bioprocess and chemical engineering**. 1. ed. London: Academic Press Inc., 1995.
- BRAGA, A. P.; CARVALHO, A. P. L.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Portaria nº 210, de 10 de novembro de 1998. Regulamento técnico da inspeção tecnológica e higiênico-sanitária de carne de aves. **Diário Oficial da União**, Brasília, 26 nov. 1998. Seção 1, p. 226.

CORAZZA, F. C.; CALSAVARA, L. P.; MORAES, F. F.; ZANIN, G. M.; NEITZEL, I. Determination of inhibition in the enzymatic hydrolysis of cellobiose using hybrid neural modeling. **Brazilian Journal of Chemical Engineering**, v. 22, n. 1, p. 19-29, 2005.

FAGUNDES-KLEN, M. R.; FERRI, P.; MARTINS, T. D.; TAVARES, C. R. G.; SILVA, E. A. Equilibrium study of the binary mixture of cadmium-zinc ions biosorption by the *Sargassum filipendula* species using adsorption isotherms models and neural network. **Biochemical Engineering Journal**, v. 34, n. 2, p. 136-146, 2007.

HAYKIN, S. **Neural networks: a comprehensive foundation**. Delhi: Prentice Hall, 2005.

MITTAL, G. S.; ZHANG, J. Prediction of freezing time for food products using a neural network. **Food Research International**, v. 33, n. 7, p. 557-562, 2000.

MITTAL, G. S.; ZHANG, J. Artificial neural network for the prediction of temperature, moisture and fat contents in meatballs during deep-fat frying. **International Journal of Food Science and Technology**, v. 36, n. 5, p. 489-497, 2001.

MITTAL, G. S.; ZHANG, J. Prediction of food thermal process evaluation parameters using neural networks. **International Journal of Food Microbiology**, v. 79, n. 3, p. 153-159, 2002.

NELDER, J. A.; MEAD, R. A simplex method for function minimization. **The Computer Journal**, v. 7, n. 4, p. 308-315, 1965.

SAVELL, J. W.; MUELLER, S. L.; BAIRD, B. E. The chilling of carcasses. **Meat Science**, v. 70, n. 3, p. 449-459, 2005.

SILVA, L. H. M.; NEITZEL, I.; LIMA, E. P. Resolução de um modelo de reator de leito fixo não adiabático com dispersão axial utilizando redes neurais artificiais. **Acta Scientiarum. Technology**, v. 25, n. 1, p. 39-44, 2003.

SOUZA, E. C. B.; RIBEIRO, S. R. A.; BOTELHO, M. F.; KRUEGER, C. P.; CENTENO, J. A. S. Geração de Isolinhhas, com dados obtidos por levantamento GPS/L1L2, mediante a técnica de Redes Neurais Artificiais, **Acta Scientiarum. Technology**, v. 28, n. 2, p. 205-212, 2006.

SWEAT, V. E. Thermal properties of foods. In: RAO, M. A.; RIZVI, S. S. H. (Ed.). **Engineering properties of foods**. New York: Dekker, 1995. p. 49-87.

Received on May 11, 2008.

Accepted on December 1, 2008.

License information: This is an open-access article distributed under the terms of the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.