

**ELIANE CALOMINO GONÇALVES**

**REDES NEURAS ARTIFICIAIS APLICADAS AO PROCESSAMENTO  
TÉRMICO DE ALIMENTOS**

Tese apresentada à **Universidade Federal de Viçosa**, como parte das exigências do Programa de Pós-Graduação em Ciência e Tecnologia de Alimentos, para obtenção do título de “**Doctor Scientiae**”

**VIÇOSA**  
**MINAS GERAIS - BRASIL**  
**2003**

**ELIANE CALOMINO GONÇALVES**

**REDES NEURAIIS ARTIFICIAIS APLICADAS AO PROCESSAMENTO  
TÉRMICO DE ALIMENTOS**

Tese apresentada à **Universidade Federal de Viçosa**, como parte das exigências do Programa de Pós-Graduação em Ciência e Tecnologia de Alimentos, para obtenção do título de “**Doctor Scientiae**”

APROVADA: 25 de agosto de 2003.

---

Prof<sup>ª</sup> Jane Sélia dos Reis Coimbra  
(Conselheira)

---

Prof. José Antonio Marques Pereira  
(Conselheiro)

---

Prof. Roselito de Albuquerque Teixeira

---

Dr. Sérgio Henriques Saraiva

---

Prof. Luis Antonio Minim  
(Orientador)

Ao meu marido, Ronaldo, pelo grande apoio  
Aos meus filhos, Rodrigo e Henrique, pelo imenso carinho  
Aos meus pais, Roberto e Ilma, pela vida.

## AGRADECIMENTOS

Ao Professor Luis Antonio Minim, pela orientação e apoio prestado durante a realização deste trabalho.

À Professora Jane Sélia dos Reis Coimbra, que contribuiu para a realização deste trabalho.

Aos Professores José Antônio Marques Pereira e Antônio Carlos Gomes de Souza, pela grande contribuição prestada durante a execução deste trabalho.

Ao Professor Afonso Mota Ramos, pelos conselhos durante o desenvolvimento deste trabalho e pela amizade.

Ao Professor Roselito de Albuquerque Teixeira, pelos importantes conselhos.

Ao Eng. Sérgio Henriques Saraiva da EMBRAPA pela contribuição durante a execução do trabalho em questão.

Ao Professor Lúcio Gomide, pelo empréstimo dos equipamentos utilizados na execução do trabalho.

À CAPES pelo apoio financeiro concedido.

Aos funcionários do DTA , em especial ao José Raimundo, José Geraldo, Sr. Valente e Sr. Luís pela boa vontade e apoio.

## CONTEÙDO

Agradecimentos	iii
Resumo	vi
Abstract	vii
Introdução Geral	1
Referências Bibliográficas	3

### **CAPITULO 1** – Cálculo de processamento térmico de alimentos: uma revisão

Resumo	5
1. Introdução	5
2. Considerações sobre o processamento térmico	6
3. Cálculo do processamento térmico de alimentos	10
4. Conclusão	17
5. Referências Bibliográficas	17

### **CAPITULO 2** – Modelagem do processamento térmico de alimentos

Resumo	22
1. Introdução	22
2. Materiais e Métodos	24
2.1. Modelagem utilizando redes neurais artificiais	25
3. Resultados e Discussão	27
3.1 Aprendizagem e Treinamento	28
4. Conclusão	33
5. Referências Bibliográficas	33

### **CAPITULO 3** - Comparação entre técnicas para a predição da temperatura durante o processamento térmico de alimentos enlatados

Resumo	36
1. Introdução	36

2. Materiais e Métodos	40
2.1. Modelagem utilizando redes neurais artificiais	41
3. Resultados e Discussão	42
3.1 Aprendizagem e Treinamento	42
4. Conclusão	48
5. Referências Bibliográficas	48

**CAPITULO 4** – Desenvolvimento de nova metodologia para definição do processamento térmico de alimentos: aplicação de redes neurais

Resumo	51
1. Introdução	51
2. Materiais e métodos	54
2.1. Modelagem utilizando redes neurais artificiais	55
3. Resultados e Discussão	57
4. Conclusão	66
5. Referências Bibliográficas	67

**CONCLUSÕES GERAIS**

1. Conclusões	70
2. Sugestões	71

## RESUMO

GONÇALVES, Eliane Calomino, D. S. Universidade Federal de Viçosa, agosto de 2003. **Redes Neurais Artificiais Aplicadas ao Processamento Térmico de Alimentos**. Orientador: Luis Antonio Minim. Conselheiros: Jane Sélia dos Reis Coimbra, José Antonio Marques Pereira e Afonso Mota Ramos

O presente trabalho teve como objetivo desenvolver um modelo matemático usando a técnica de redes neurais como alternativa potencial aos métodos existentes para o cálculo do processamento térmico de alimentos enlatados. A rede construída teve como variáveis de entrada: o tempo de processo, a temperatura da autoclave e a temperatura do centro do produto para o tempo presente e tempos anteriores. A variável de saída foi a temperatura do ponto frio. Para o treinamento da rede, um conjunto de dados em função das variáveis operacionais tempo e temperatura foi obtido através do processamento do produto em autoclave vertical. A rede selecionada foi a 5-8-9-1, a qual apresentou excelente capacidade de generalização, com um erro relativo médio de 0,022. A precisão e a habilidade do modelo de redes neurais foram comparadas com os métodos de Ball e Stumbo, ambas com respeito ao valor de F do processo, demonstrando a superioridade da técnica de redes neurais. A etapa de resfriamento foi estudada separadamente a partir de uma rede *back-propagation* desenvolvida com o objetivo de prever a contribuição do valor de F do processo para diferentes valores de temperatura no centro do produto, no início e no final do resfriamento. A rede construída teve como variáveis de entrada: a temperatura do centro do produto no início do resfriamento, a temperatura da água de resfriamento e a temperatura do ponto frio no final do resfriamento. A variável de saída foi o valor de F. No treinamento da rede foi usado o mesmo conjunto de dados em função das variáveis operacionais tempo e temperatura obtido em autoclave vertical. A rede selecionada para a etapa de resfriamento foi a rede (5-14-10-1) e apresentou excelente capacidade de generalização, com um erro relativo médio de 0,706. Redes neurais apresentaram grande capacidade para a modelagem do processamento térmico de alimentos quando analisado o processo completo e a etapa de resfriamento em separado, predizendo acertadamente as novas temperaturas do produto e os novos valores de F, respectivamente. Sendo então demonstrada precisão, simplicidade e compatibilidade *on line*.

## ABSTRACT

GONÇALVES, Eliane Calomino, D. S. Universidade Federal de Viçosa, august de 2003. **Artificial Neural network applied to Thermal Processing of Food.** Adviser: Luis Antonio Minim. Committee members: Jane Sélia dos Reis Coimbra, José Antonio Marques Pereira and Afonso Mota Ramos

The present work had as objective to develop a mathematical model using the technique of neural networks as potential alternative to the existent methods for the calculation of the thermal processing of canned food in order to determine the temperature of the cold point of the product starting from the initial conditions of the process and of the temperature of the autoclave. The built network had as input variables: the time of process, the temperature of the autoclave and the temperature of the center of the product for the time present and previous times. The output variable went to temperature in the center of the product in the time. For the training of the network, a group of data in function of the variables operational time and temperature was obtained through the processing of the product in vertical autoclave. The selected network went to network (5-8-9-1), which presented excellent generalization capacity, with a mean relative error of 0,022. The precision and ability of the model of neural networks were compared with the methods of Ball and Stumbo, both with regard to the value of F of the process, demonstrating the superiority of the technique of neural networks. The cooling stage was studied separately starting from a network back-propagation developed with the objective of predicting the contribution of the value of F of the process for different temperature values in the center of the product in the beginning and in the end of the cooling. The built network had as input variables: the temperature of the center of the product in the beginning of the cooling, the temperature of the cooling water and the temperature of the center of the product in the end of the cooling. The output variable was the value of F. In the training of the network the same group of data was used in function of the variables operational time and temperature obtained in vertical autoclave. The network selected for the cooling stage went to network (5-14-10-1) and it presented excellent generalization capacity, with a mean relative error of 0,706. Neural networks presented great capacity for the modeling of the thermal processing of food when analyzed the complete process and the cooling stage in separate predicting the new temperatures of the product and the new values of F wisely, respectively. Being demonstrated precision, simplicity and on line compatibility.



## INTRODUÇÃO GERAL

O processamento térmico de alimentos enlatados em autoclaves tem sido um dos métodos mais utilizados para conservação de alimentos. Consiste em aquecer um produto alimentício, dentro de um recipiente, em autoclave pressurizada por tempo e temperatura pré-estabelecidos por engenheiros de processo. Estes parâmetros são calculados com base no conhecimento da resistência térmica de microorganismos e componentes dos alimentos, de modo a garantir a qualidade final do produto em relação ao risco à saúde do consumidor e estáveis à temperatura de armazenamento.

Atualmente, a solução do problema de transferência de calor por métodos numéricos tem sido utilizada com mais frequência devido ao advento de novas gerações de computadores. Estas técnicas permitem a resolução do modelo completo do fenômeno, incluindo sua característica multivariável no tempo e no espaço (RODRIGUES et al., 1998). A aplicação destes métodos tem sido de grande importância em estudos de otimização e controle de processos térmicos em autoclaves, incluindo os problemas causados por desvios de processo, o que é solucionado de modo pouco preciso e trabalhoso pelos métodos tradicionais.

Simulações com modelos matemáticos, que são reconhecidas como alternativas práticas para métodos experimentais, são utilizadas para gerar perfis de temperatura em condições de processamento térmico no ponto de aquecimento mais lento através de simulações em computadores. Deste modo, pode-se estimar o efeito letal do processo de esterilização, avaliando o tratamento térmico aplicado, e utilizando também técnicas de otimização e controle de processos a fim de aumentar a eficiência do processo.

Ainda que a capacidade de modelos matemáticos de transferência de calor de simular o processamento térmico seja reconhecida, requerem informações exatas das propriedades termofísicas do produto, que são ainda dificultadas pela alteração constante dos parâmetros do processo.

O emprego de redes neurais têm a vantagem de não necessitarem do conhecimento da relação entre as variáveis de entrada e saída, e ao invés disso, descobrem essas relações através de sucessivos treinamentos. Modelos de redes neurais podem aprender com exemplos, incorporar muitas variáveis, e fornecer respostas adequadas e rápidas para novas informações não apresentadas previamente. As características que fazem com que as redes neurais sejam atrativas para inúmeras

aplicações são a sua capacidade de aprender e generalizar relações numa série de dados complexos (SABLANI e SHAYYA, 2001).

A técnica de redes neurais têm se tornado de grande importância no processamento de alimentos e engenharia, sendo utilizada para a resolução de grande variedade de problemas, principalmente em aplicações como controle de processos, interpretação de sensores e modelos dinâmicos (GARCIA et al., 1995).

Os modelos de redes neurais têm sido aplicados como alternativas para os métodos de cálculos para o processamento térmico convencional. A precisão e habilidade das redes neurais artificiais quando comparadas com técnicas convencionais baseadas em modelos fenomenológicos, demonstraram grande potencial para aplicação em cálculos de processos com vantagens como precisão, simplicidade e compatibilidade *on line*.

#### OBJETIVO GERAL:

O objetivo deste trabalho é aplicar a técnica de redes neurais para desenvolver um modelo matemático preditivo do processo de esterilização. Pretende-se estimar a temperatura do ponto frio de um alimento acondicionado em um recipiente, a partir da temperatura ou pressão da autoclave, sendo que o cálculo do processo deverá ser realizado de forma *on line*. Deste modo, o algoritmo matemático será responsável pelas correções dos processos, no que diz respeito a possíveis variações nas condições da autoclave. Dados experimentais serão tomados em autoclave a fim de validar o modelo proposto.

#### OBJETIVOS ESPECÍFICOS:

- Realizar o processamento térmico de um produto cárnico a fim de obter um conjunto de dados experimentais em função das variáveis tempo e temperatura para o desenvolvimento de uma estrutura de rede neural.
- Desenvolver um modelo matemático baseado na técnica de redes neurais para o cálculo do processamento térmico de alimentos enlatados a fim de determinar a

temperatura do ponto frio do produto a partir das condições iniciais do processo e da temperatura da autoclave.

- Comparar a precisão e habilidade do modelo de redes neurais com os métodos de Ball e Stumbo.
- Desenvolver uma rede para a etapa de resfriamento a fim de verificar a contribuição da letalidade no resfriamento.

### **REFERÊNCIAS BIBLIOGRÁFICAS**

GARCIA, L., ARGUESO, F., GARCIA, A., DIAZ, M. Application of neural networks for controlling and predicting quality parameters in beer fermentation. **Journal of Industrial Microbiology**, v. 15, p. 401-406, 1995.

RODRIGUES, A. D., SCHIMDT, F. L., VITALI, A. A., TEIXEIRA NETO, R. O., TEIXEIRA, A. A., GERMER, S. P. M., SADAHIRA, M. S. Comparação entre técnicas numéricas para a resolução do problema de transferência de calor em alimentos enlatados. **Ciência e Tecnologia de Alimentos**, v. 18, n. 2, p. 230-236, 1998.

SABLANI, S. S., SHAYYA, W. H. Computerization of Stumbo's method of thermal process calculations using neural networks. **Journal of Food Engineering**, v. 47, p. 233-240, 2001.

# **CAPÍTULO 1**

## **CÁLCULO DE PROCESSAMENTO TÉRMICO DE ALIMENTOS: UMA REVISÃO**

## **RESUMO**

Este trabalho apresenta uma breve revisão do desenvolvimento de modelos matemáticos preditivos do processo de esterilização de alimentos enlatados em autoclaves. A aplicação de métodos numéricos tem sido de grande importância em estudos de otimização e controle de processos térmicos, incluindo os problemas causados por desvios de processo, o que é solucionado de modo pouco preciso e trabalhoso por técnicas tradicionais. Embora as metodologias de modelagem matemática, através de aplicações de balanço diferencial de energia térmica em estado não estacionário do processo de esterilização, sejam muito utilizadas elas requerem informações exatas das propriedades termofísicas do produto. Os modelos de redes neurais têm sido usados como alternativas aos métodos de cálculos para o processamento térmico convencional.

### **1. INTRODUÇÃO**

O processamento térmico é uma das principais tecnologias de preservação de alimentos que visa garantir a qualidade final do produto relativa ao risco à saúde do consumidor. A esterilização térmica de alimentos enlatados em autoclaves tem sido um dos métodos de preservação mais utilizados nos últimos duzentos anos (TEIXEIRA e TUCKER, 1997). Nicholas Appert introduziu este método pela primeira vez em 1810.

O conceito de processamento térmico é baseado no aquecimento dos alimentos enlatados por tempo e temperatura pré-estabelecidos por engenheiros de processo. Estes parâmetros são calculados com base em dados da resistência térmica de microorganismos e de transferência de calor. A técnica de pasteurização, um tratamento de calor relativamente moderado e iniciada por Louis Pasteur quase cinquenta anos depois de Appert, visa a destruição de microorganismos patogênicos em alimentos proporcionando a extensão da vida de prateleira (RAMASWAMY e ABBATEMARCO, 1996).

Um progresso significativo foi alcançado na microbiologia de alimentos, com os estudos da cinética de destruição térmica de microorganismos e da transferência de calor dos alimentos envasados. Em decorrência foram observados avanços nos cálculos de processos térmicos e conseqüentemente no projeto de equipamentos, sendo

desenvolvidas versões aperfeiçoadas de sistemas de autoclave em linhas contínuas para esterilização térmica de alimentos envasados e sistemas para condução de processos de alta temperatura em pequeno espaço de tempo (HTST), com operação em modo batelada ou contínuo, em autoclave estacionária ou rotativa. O advento do processamento asséptico e de autoclaves com agitação totalmente automatizadas revolucionaram a indústria de alimentos nas últimas décadas (RAMASWAMY e ABBATEMARCO, 1996). Métodos combinados, como aquecimento com redução da atividade de água, com redução de valores de pH e com ausência de oxigênio, estão sendo introduzidos continuamente, especialmente para produtos termosensíveis preservando a cor, sabor e outros atributos de qualidade (GOULD, 1996).

Atualmente, a solução do problema de transferência de calor por métodos numéricos tem sido utilizada com maior frequência devido ao advento de novas gerações de computadores. Estas técnicas permitem a resolução de modelos complexos do processo, incluindo sua característica multivariável no tempo e no espaço. A aplicação destes modelos tem sido de grande importância em estudos de otimização e controle de processos térmicos em autoclaves, incluindo os problemas causados por desvios de processo, o que são solucionados de modo pouco preciso e trabalhoso pelos métodos tradicionais (RODRIGUES et al., 1998).

Simulações computacionais com modelos matemáticos, são utilizadas para gerar perfis de temperatura em condições de processamento térmico no ponto de aquecimento mais lento. Deste modo, pode-se estimar o efeito letal do processo de esterilização, avaliando o tratamento térmico aplicado, e utilizando também de técnicas de otimização e controle de processos a fim de aumentar a eficiência do processo (ALONSO et al., 1998).

## **2. CONSIDERAÇÕES SOBRE O PROCESSAMENTO TÉRMICO**

A esterilização térmica de alimentos enlatados em autoclaves tem sido um dos métodos de preservação mais utilizados nos últimos duzentos anos (TEIXEIRA e TUCKER, 1997). O processamento térmico é baseado no aquecimento dos alimentos enlatados por um certo período de tempo a uma dada temperatura para obter um produto dentro dos padrões de segurança para o consumidor. Tipicamente o método de esterilização consiste no aquecimento dos recipientes em autoclaves pressurizados, a temperaturas específicas por períodos de tempos prescritos. Pode-se associar ao

processo térmico alguma degradação dos fatores sensoriais. O maior objetivo dos cálculos para o processo térmico é determinar o tempo a uma dada temperatura constante necessário para atingir uma letalidade pré selecionada ou avaliar a letalidade para um dado processo (AFAGHI et al., 2001).

Os procedimentos mais comuns para inativar ou destruir os microorganismos presentes nos alimentos são aplicação: de temperaturas elevadas, de substâncias químicas e em menor extensão de radiações ionizantes. Ao usar estes tratamentos, a flora microbiana do alimento sofre um decréscimo contínuo de acordo com a dinâmica do processo de morte (MERIDA RAMOS et al., 1997).

A esterilização pode prevenir a transmissão de doenças, a contaminação de materiais por microorganismos, acabar com a competição por nutrientes permitindo o crescimento de certos cultivos de microorganismos específicos como bebidas fermentadas, e produção de antibióticos (LEWIS, 1993).

O processo de aquecimento sob pressão ainda pode ser visto como o principal método de esterilização para o alimento enlatado de baixa acidez. O efeito de um aquecimento contínuo a altas pressões, pode levar a uma diminuição da qualidade do alimento, sendo, portanto, a pressão, um importante fator no controle de processos.

Os alimentos envasados são denominados comercialmente estéreis e normalmente têm uma vida de prateleira de pelo menos 6 meses (POVOA e MORAIS-SANTOS, 1997). A esterilidade comercial descreve a situação em que existe uma pequena probabilidade de serem encontrados microorganismos viáveis no produto, sem haver deterioração de sua qualidade durante sua vida de prateleira (LEWIS, 1993).

O microorganismo considerado mais importante para determinar o efeito do tratamento térmico na esterilização de conservas é o *clostridium botulinum*, cujos esporos são muito resistentes ao calor e produz uma toxina potente em alimentos enlatados (provoca intoxicações alimentares que frequentemente terminam em morte), embora estes normalmente não germinem em pH abaixo de 4,5. Por esta razão os alimentos se classificam como de baixa acidez (pH maior que 4,5) e ácidos (LEWIS, 1993).

Foi estabelecido que o processamento mínimo deve ser severo o suficiente para reduzir a população de *Clostridium botulinum* a pelo menos doze reduções decimais. Este tratamento é capaz de reduzir doze ordens decimais o número inicial de microorganismos de *clostridium botulinum* presentes no meio. Tal processo conhece-se como cocção botulínica e é realizado aquecendo o alimento a uma temperatura de

121<sup>0</sup>C durante 3 minutos (KORMENDY et al., 2000). Esta temperatura de 121<sup>0</sup>C utiliza-se freqüentemente como temperatura de referência para comparar os processos térmicos (LEWIS, 1993).

De um ponto de vista prático, a eficiência de um tratamento térmico na destruição de microorganismos existentes em um alimento depende do tempo do processo e da concentração inicial de microorganismos no produto (MERIDA RAMOS et al., 1997).

A inativação térmica dos microorganismos normalmente segue uma cinética de reação de primeira ordem, ou seja, a taxa de destruição à temperatura constante é diretamente proporcional ao número de esporos sobreviventes no alimento (MERIDA RAMOS et al., 1997).

O tempo de morte térmica representa o tempo necessário, em cada temperatura, que leva a uma redução no número de microorganismos, equivalente à redução provocada pela cocção botulínica. O valor de esterilização (F) de um tratamento é definido como o tempo em minutos, a 121<sup>0</sup>C, capaz de destruir um número específico de esporos bacterianos. O tempo necessário para reduzir o número de microorganismos a um décimo do inicial (ou 90% de destruição), a uma determinada temperatura, é denominado de tempo de redução decimal (D). O valor z indica o aumento da temperatura necessário para reduzir à décima parte o tempo de redução decimal (D). Corresponde ao número de graus necessários para aumentar a temperatura até que a curva de termorresistência atravesse um ciclo logaritmo (WIRTH, 1992).

O mesmo conceito pode ser estendido à cinética de inativação de enzimas onde a enzima em um determinado alimento é sujeita a um processo térmico a uma dada temperatura. O resultado da atividade enzimática residual contra o tempo seria o valor D da enzima ou o índice de termorresistência, que é definido como o tempo de aquecimento em minutos requerido para inativar 90% da atividade total enzimática (MAFART, 1994).

A curva de inativação térmica para enzimas é estabelecida de modo semelhante à curva do tempo de morte térmica para bactérias. Esta é alcançada sujeitando a amostra de alimento a uma série de tratamentos térmicos, a uma temperatura específica, e analisando a concentração de enzima residual. Quando não há nenhuma atividade residual mensurável, a enzima é considerada inativa e o tempo de aquecimento correspondente é chamado de tempo de inativação térmica (GERMER et al, 1995).



A taxa letal (L) expressa a letalidade de um tratamento térmico, a qualquer temperatura, em função da temperatura de referência. Por exemplo, para uma temperatura de referência de 121,1 °C e  $z = 10$  °C, pode ser calculada pela seguinte equação (MAFART, 1994):

$$L = 10^{\frac{(T-121,1)}{10}} \quad (1)$$

A avaliação do impacto de um processo térmico em eliminar microorganismos em um produto alimentício pode ser atribuída ao valor F, que é também interpretado como o equivalente em minutos, em relação à temperatura de referência, das letalidades combinadas de todas as integrações tempo-temperatura no ponto de aquecimento mais lento para o produto (ponto frio). Em termos da mudança de propriedades organolépticas e fatores de qualidade, a cinética dessas reações secundárias obedecem a uma relação de primeira ordem, do mesmo tipo que na destruição térmica de microorganismos (MAFART, 1994).

A expressão para o valor de esterilização é descrita por:

$$F = \int_0^{t_T} 10^{(T-T_{ref})/z} dt \quad (2)$$

Para alimentos com características de aquecimento por condução de calor, o ponto frio é o centro geométrico, ao passo que para alimentos com características de aquecimento por convecção de calor, o ponto frio é localizado aproximadamente a um décimo do fundo do envase. Geralmente, é assumido que, se o ponto frio recebe um processamento adequado de letalidade, então todos os outros pontos dentro do recipiente receberam um tratamento igual ou superior. O tipo de produto influencia extremamente o tipo de transferência de calor e a distribuição de temperatura no produto. Geralmente, produtos com características de aquecimento por condução são firmemente acumulados e pouco viscosos, não se movem dentro do recipiente durante o aquecimento e resfriamento (DENYS et al., 1996). Exemplos incluem cremes, purês, geléias, atum. Produtos com características de aquecimento por convecção de calor são dispostos mais livremente dentro do recipiente e podem conter sólidos particulados. Exemplos incluem sopas de legumes, ervilhas em salmoura, e fatias de fruta. Alguns produtos mostram um comportamento de aquecimento quebrado, ou seja, aquecem através de convecção no início do processo e depois mudam para condução. Exemplos

incluem produtos que contêm goma ou outros agentes espessantes (RAMASWAMY e ABBATEMARCO, 1996).

A temperatura de processamento é função das considerações de transferência de calor, as quais envolvem tempo de processo, propriedades do produto e condições iniciais e de contorno do processo. Com isso, a temperatura do alimento é dependente da temperatura inicial do produto; da localização do ponto de medida na embalagem; da difusividade térmica do produto no caso de alimentos com características condutivas de transferência de calor e do tempo (RODRIGUES et al., 1998).

### **3. CÁLCULO DO PROCESSAMENTO TÉRMICO DE ALIMENTOS**

BIGELOW et al (1920) introduziram um procedimento gráfico para avaliar a eficiência do processamento térmico de alimentos enlatados, onde os efeitos letais de dados de tempo-temperatura no ponto frio dentro de um recipiente são integrados para uma dada condição de processo. Esta técnica foi a base de um grupo de metodologias de cálculos de processamentos, que mais tarde foram chamados métodos “gerais”. O método geral é o mais preciso, pois utiliza dados reais de tempo-temperatura para cálculos de processos. Contudo, a aplicação deste método pode consumir tempo, pois para cada variação nas condições de processo, produto ou tamanho de lata, um novo conjunto de dados de tempo-temperatura é requerido. Métodos matemáticos, por outro lado, são baseados na caracterização dos parâmetros de penetração de calor como índice da taxa de aquecimento ( $f_h$ ) e fatores lag de aquecimento/resfriamento ( $j_{ch}/j_{cc}$ ) para cinética de destruição. Estes métodos matemáticos são menos restritivos que o método geral e podem acomodar variações no produto, equipamento e parâmetros de processo. Dentre os métodos mais utilizados para os cálculos de processo estão:

- Método de Ball

O método de Ball é uma das técnicas mais usadas para o cálculo do processamento térmico. O cálculo do tempo de processamento (B), a uma dada temperatura da autoclave, é baseado na equação matemática a seguir (SABLANI e SHAYYA, 2001):

$$B=f_h[\log(j_{ch}\cdot I)-\log(g)] \quad (3)$$

onde:

$f_h$  é o índice da taxa de aquecimento (min)

$j_{ch}$  é o fator lag da taxa de aquecimento,  $j_{ch}=(T_1-T_a)/(T_1-T_0)$

$T_1$  é a temperatura da autoclave

$T_a$  é o intercepto da linha reta da primeira curva de aquecimento com o eixo da escala logarítmica situada no tempo corrigido

$T_2$  é temperatura do meio de resfriamento

$T_0$  é temperatura inicial do produto

$g$  é a diferença entre a temperatura da autoclave e a temperatura no ponto frio no final do aquecimento

$I$  é a diferença entre a temperatura da autoclave e a temperatura inicial do produto

Dados de penetração de calor são organizados de modo que o logaritmo da diferença entre a temperatura da autoclave e a temperatura no ponto frio durante o aquecimento seja representada contra o tempo em um gráfico semi-logarítmico. Após uma fase lag inicial hiperbólica, o processo de aquecimento é denotado por uma linha reta. O tempo requerido para a porção da linha reta da curva de aquecimento atravessar um ciclo logarítmico é o parâmetro do efeito da temperatura do aquecimento,  $f_h$ , e o fator lag é  $j_{ch}$ . A curva de resfriamento é construída do mesmo modo, onde o logaritmo da diferença entre a temperatura do produto no ponto frio e a temperatura da água de resfriamento é representada contra o tempo, após interromper a alimentação de vapor e o produto iniciar o resfriamento. O parâmetro do efeito da temperatura do resfriamento,  $f_c$ , e o fator lag de resfriamento,  $j_{cc}$ , são calculados de maneira similar ao  $f_h$ , e  $j_{ch}$ . A letalidade e o tempo de processo são obtidos usando as condições de processamento (temperatura da autoclave e temperatura inicial) e tabelas ou gráficos de parâmetros relacionados ( $f_h/U$  e  $g$ ). As considerações mais significativas feitas no desenvolvimento dessas tabelas e gráficos foram igualar o fator lag de resfriamento ( $j_{cc}$ ) a 1.41 e a taxa de aquecimento à de resfriamento ( $f_h=f_c$ ). Evidentemente, para desvios de processo com essas considerações, o método de Ball é inexato. Assim procedimentos adicionais têm sido desenvolvidos para superar as limitações e considerações empregadas no método de Ball (AFAGUI et al., 2001, GERMER et al., 1995).

- Método de Stumbo

Revisando o método de Ball para aumentar sua precisão, Stumbo e Longley (1966) apud AFAGUI et al.(2001) publicaram uma nova série de tabelas acomodando a variabilidade com respeito ao parâmetro  $j_{cc}$ . O procedimento para o cálculo do tempo de processamento e letalidade neste método é similar ao método de Ball no sentido que se baseia em curvas de aquecimento e resfriamento e assume que  $f_h$  é igual a  $f_c$  (AFAGHI et al., 2001). O método de Stumbo eliminou algumas simplificações utilizadas no desenvolvimento do método de Ball e outros métodos matemáticos. Ao invés de confiar em apenas uma tabela, Stumbo desenvolveu 57 tabelas cobrindo uma ampla faixa de valores  $z$  (-13,3 a 93,3 °C) e fatores lag de resfriamento,  $j_{cc}$ , (0,4 – 2,0) que permitem estimar o tempo de processamento depois de estabelecer a diferença entre as temperaturas do meio de aquecimento e no ponto frio no final do aquecimento (valor  $g$ ). O desenvolvimento das tabelas é também útil para prever a letalidade do processo depois de estabelecer a razão entre a taxa de aquecimento ( $f_h$ ) e o valor de esterilização ( $F$ ) de um processo térmico. Embora preciso, o método de Stumbo é de difícil realização já que envolve 57 tabelas comparado ao método de Ball, onde apenas uma tabela é utilizada. Este fato explica a aplicação limitada do método de Stumbo na indústria de alimentos (STUMBO, 1973).

O método de Stumbo para o cálculo do tempo de processamento ( $B$ ), a uma dada temperatura da autoclave, é baseado na equação matemática desenvolvida por Ball (Equação 3). Com exceção de  $g$  todos os parâmetros da equação 3 podem ser obtidos através da curva de penetração. Na prática,  $g$  pode ser encontrado através de uma série de tabelas que relacionam  $g$  a  $f_h/F$  para  $z$  específicos e  $j_{cc}$  (obtido da curva de resfriamento). O parâmetro  $F$  representa o tempo de processo equivalente em minutos a uma dada temperatura de referência para um valor selecionado de  $z$ . Nos processos de esterilização, geralmente, a temperatura de referência é de 121,1°C e o valor de  $z$  igual a 10° C (STUMBO, 1973).

- Modelos fenomenológicos

Modelos matemáticos desenvolvidos para solução do problema de transferência de calor em alimentos envasados têm sido aplicados com sucesso na otimização e

controle (TEIXEIRA e TUCKER, 1997). A principal característica desses modelos é a predição do perfil de temperatura baseado em equações de transferência de calor. Esses modelos requerem parâmetros e dados do produto e do sistema como a difusividade térmica do produto, calor específico, densidade, coeficientes de transferência de calor dos meios de aquecimento e resfriamento. Quando essas condições são conhecidas, dados de tempo-temperatura em qualquer posição específica do produto podem ser obtidos resolvendo as equações correspondentes (AFAGUI et al., 2001).

TEIXEIRA e TUCKER (1997) desenvolveram um algoritmo matemático baseado na técnica de diferenças finitas na resolução das equações de transferência de calor para aplicação no controle de processos térmicos em autoclave em tempo real, incluindo os problemas causados por desvios de processo.

RODRIGUES et al. (1998) compararam as técnicas de resolução numérica por diferenças finitas e Runge Kutta-Gill de quarta ordem com passo de integração variável para a simulação do modelo de transferência de calor em regime transiente bidimensional em coordenadas cilíndricas e unidimensional em coordenadas esféricas, aplicado a alimentos enlatados processados em autoclave. Foram realizados ensaios de penetração de calor em autoclave a vapor, utilizando dois produtos distintos, um com características de aquecimento por condução e o outro por convecção. Os métodos apresentaram o mesmo desempenho na reprodução dos dados reais, utilizando-se as duas técnicas de resolução numérica inclusive nos casos onde ocorreram desvios de processo. O método por Runge-Kutta-Gill foi duas vezes mais rápido que o método de diferenças finitas, mantendo-se a mesma precisão no ajuste. Este resultado possibilita a resolução numérica do problema em tempos menores, importante na aplicação do modelo ao controle de desvios de processo em tempo real.

A esterilização térmica de alimentos enlatados têm sido estudada com a ajuda de modelos baseados em dinâmica de fluidos computacionais como no caso da análise e simulação de convecção natural de um líquido viscoso (sopa de cenoura) em sachê tridimensional (12 cm de largura, 4 cm de altura e 22 cm de comprimento). As equações de continuidade, momento e conservação de energia foram solucionadas utilizando o método de volumes finitos. Um software de dinâmica dos fluidos computacional foi usado para gerar perfis de temperatura. Os resultados mostraram que existe fluxo circular do líquido dentro do sachê. A região fria cobre toda a área transversal do sachê nos primeiros estágios do aquecimento e depois fica a uma distância de aproximadamente 20 a 30% do fundo (GHANI et al., 2001).

O processamento térmico em batelada foi avaliado utilizando técnicas de controle de processos a fim de evitar o super processamento do produto e degradação de parâmetros de qualidade sensorial e nutricional (ALONSO et al., 1998).

- Modelos baseados em redes neurais

A rede neural é um sistema de neurônios ligados por conexões sinápticas que é dividido em neurônios de entrada, que recebem estímulos do meio externo, neurônios internos ou ocultos e neurônios de saída, que se comunicam com o exterior (FILHO, 1996; BARRETO, 1997).

Redes neurais têm a vantagem de não necessitarem do conhecimento da relação entre as variáveis de entrada e saída, e ao invés disso, descobrem essas relações através de sucessivos treinamentos. Modelos de redes neurais podem aprender com exemplos, incorporar muitas variáveis, e fornecer respostas adequadas e rápidas para novas informações não apresentadas previamente. As características que fazem com que as redes neurais sejam atrativas para inúmeras aplicações são a sua capacidade de aprender e generalizar relações numa série de dados complexos (SABLANI e SHAYYA, 2001).

O impacto que a rede neural artificial causou nos domínios da engenharia química nos últimos anos foi grande o suficiente para chamar a atenção para esta promissora ferramenta científica (JINESCU e LAVRIC, 1995). A técnica de redes neurais tem se tornado de grande importância no processamento de alimentos e engenharia, sendo utilizada para a resolução de grande variedade de problemas, principalmente em aplicações como controle de processos, interpretação de sensores e modelos dinâmicos (GARCIA et al., 1995).

Algumas das aplicações de redes neurais em alimentos incluem: predição do tempo de vida de prateleira do leite (VALLEJO et al., 1995), desenvolvimento de um protótipo baseado em redes neurais para um sistema de controle supervisionado para a fermentação do *Bacillus thuringiensis* (ZHANG et al., 1994), predição da qualidade de cozimento do pão baseado em testes de qualidade da farinha de trigo (HORIMOTO et al., 1995), modelagem de processos de secagem (JINESCU & LAVRIC, 1995), controle e predição de parâmetros de qualidade na fermentação da cerveja (GARCIA et al., 1995), modelagem e simulação de extração líquido líquido (ALDRICH & SLATER, 1995; SARAIVA et al., 1998).

SABLANI et al. (1995) utilizaram redes neurais na otimização de processamento térmico, onde um algoritmo baseado na técnica de diferenças finitas foi desenvolvido para prever o efeito de temperatura em alimentos sob variadas condições processo. As letalidades dos tratamentos foram obtidas para uma faixa de variáveis de entrada (tamanho da lata, difusividade térmica do alimento, parâmetros cinéticos de fatores de qualidade) e temperaturas de esterilização entre 110 e 134°C (com intervalos de 2°C). O algoritmo *backpropagation* foi utilizado para treinamento da rede neural. As condições ótimas obtidas foram utilizadas para o treinamento da rede neural, onde as temperaturas ótimas de esterilização foram previstas com acuracidade de  $\pm 0.5^\circ\text{C}$ .

MITTAL & ZHANG (2000) utilizaram redes neurais artificiais para prever a temperatura e a umidade de salsichas durante o tratamento térmico e concluíram ser este um método simples, conveniente e preciso. Razão de gordura, teor inicial de umidade, temperatura inicial, raio da salsicha, temperatura ambiente, umidade relativa e tempo de processo foram as variáveis de entrada. Temperatura no centro da salsicha, temperatura média da salsicha e umidade média contida na salsicha foram as saídas. Os dados para treinamento da rede foram obtidos através da resolução dos modelos de transferência de calor e massa aplicados para simular os perfis de temperatura e umidade da salsicha. O método utilizado para o treinamento da rede neural foi o de *back-propagation*. A seleção de nodos intermediários, taxa de aprendizagem, variáveis de entrada foram importantes para a predição da rede. A razão de gordura não foi considerada um fator de importância nas predições.

AFAGHI et al. (2001) avaliaram aplicação de redes neurais artificiais como alternativas aos métodos de cálculos para o processamento térmico convencional. Simulações com modelos fenomenológicos foram utilizadas para gerar perfis de temperatura em uma ampla faixa de tamanhos de latas sob diferentes condições de operação do processamento térmico. Dados de tempo-temperatura foram empregados para avaliar os parâmetros de penetração de calor,  $f_h$ ,  $j_{ch}$ ,  $f_c$  e  $j_{cc}$  como também computar a letalidade e o tempo de processo. Esses dados foram usados para desenvolver a rede neural. Os métodos de Ball, Stumbo e Pham também foram aplicados no cálculo dos tempos de processo e as letalidades. A precisão e habilidade dos modelos neurais foram comparadas com os métodos tradicionais, ambos com respeito ao tempo de processo e a letalidade partindo de dados do modelo matemático como referência. Os resultados dos cálculos de processo do modelo neural foi equivalente, e algumas vezes melhor e mais flexível que os métodos de Stumbo e Pham.

O processamento térmico apresenta um comportamento que varia com o tempo. Portanto, as redes mais adequadas são as que oferecem características dinâmicas ao mapeamento realizado pela rede, tornando-a sensível a sinais que variam com o tempo. Para uma rede ser considerada dinâmica, é preciso que possua memória. Existem basicamente duas formas de prover memória a uma rede neural: introduzir atraso no tempo e utilizar redes recorrentes. Das diversas variações de arquiteturas recorrentes, o método mais simples é o algoritmo *back-propagation through time*, em que a rede é expandida no tempo (BRAGA et al, 2000).

O algoritmo *back-propagation* procura minimizar o erro obtido pela rede ajustando pesos e considera que a minimização do erro para cada padrão individualmente leva à minimização do erro total. O erro total é definido da seguinte forma:

$$E = \frac{1}{2} \sum_{j=1}^k (d_j - y_j)^2 \quad (4)$$

em que: E é a medida de erro total, k é o número de unidades de saída,  $d_i$  é a i-ésima saída desejada e  $y_i$  é a i-ésima saída gerada pela rede.

onde:

$$y_j = f_j(net_j) \quad (5)$$

$$net_j = \sum_{i=1}^n x_i w_{ji} \quad (6)$$

$$w_{ji}(t+1) = w_{ji}(t) + \mathbf{hd}_j(t)x_i(t) \quad (7)$$

Se o nodo for da camada de saída, o erro  $\delta_j$  será definido pela equação (8)

$$\mathbf{d}_j = (d_j - y_j) f'(net_j) \quad (8)$$

Se o nodo for da camada intermediária, o erro  $\delta_j$  será definido pela equação (9).

$$\mathbf{d}_j = f'(net_j) \sum_l \mathbf{d}_l w_{lj} \quad (9)$$



A constante  $n$  representa o número de conexões de entrada do nodo  $j$ , e  $w_{ji}$ , o peso da conexão entre a entrada  $x_i$  e o nodo  $j$  e  $\eta$  é a taxa de aprendizagem.

#### 4. CONCLUSÃO

O objetivo principal da indústria de alimentos é prover uma grande variedade de produtos que sejam considerados seguros e de alta qualidade. Isto representa um desafio real para empresas processadoras de alimentos já que, além das populações microbianas que causam deterioração e preocupação para a saúde pública, os nutrientes e outros atributos desejáveis também estão sujeito à degradação. Modelos matemáticos desenvolvidos para solução do problema de transferência de calor em alimentos têm sido aplicados com sucesso na otimização e controle. A principal característica desses modelos é a predição do perfil de temperatura baseado em equações de transferência de calor.

Ainda que a capacidade de modelos matemáticos de transferência de calor de simular o processamento térmico seja reconhecida, requerem informações exatas das propriedades termofísicas do produto e dos coeficientes de transferência de calor, que são ainda dificultadas pela alteração constante dos parâmetros do processo.

Os modelos de redes neurais têm sido aplicados como alternativas para os métodos de cálculos para o processamento térmico convencional. A precisão e habilidade das redes neurais artificiais quando comparadas com técnicas convencionais baseadas em regressão e modelos, demonstraram grande potencial para aplicação em cálculos de processos com vantagens como precisão, simplicidade e compatibilidade *on line*.

#### 5. REFERÊNCIAS BIBLIOGRÁFICAS

AFAGHI, M., RAMASWAMY, H. S., PRASHER, S. O. Thermal process calculations using artificial neural network models. **Food Research International**, v. 34, p. 55-65, 2001.

ALDRICH, C., SLATER, M. J. Neural separation – how neural networks will lead to better control and simulation of extraction columns. **The Chemical Engineer**, v. 15,

- p. 11-18, 1995.
- ALONSO, A. A., BANGA, J. R., PEREZ-MARTIN, R. Modeling and adaptive control for batch sterilization. **Computers Chem. Eng.**, v. 12, n. 3, p. 445-458, 1998.
- BARRETO, J. M. Introdução às redes neurais artificiais. **Anais da V Escola de Informática da SBC Regional Sul**, p. 41-71, 1997.
- BIGELOW, W. C., BOHART, G. S., RICHARDSON, A. C., BALL, O., F. C. Heat penetration in processing canned foods. **National Canners Association**, 1920. 16L.
- BRAGA, A. P., CARVALHO, A. P. L. F., LUDEMIR, T. B. Redes Neurais Artificiais: Teoria e Aplicações. **Editora LTC**, 2000. 262 p.
- DENYS, S., NORONHA, J., STOFOROS, N. G., HENDRICKX, M., TOBBACK, P. Evaluation of process deviations, consisting of drops in rotational speed, during thermal processing in foods in rotary water cascading retorts. **Journal of Food Engineering**, v. 30, p.327-338, 1996.
- FILHO, E. C. B. C. Modelagem, aplicações e implementações de redes neurais. **Anais da IV escola Regional de Informática da SBC Regional Sul**, p. 36-53, 1996.
- GARCIA, L., ARGUESO, F., GARCIA, A., DIAZ, M. Application of neural networks for controlling and predicting quality parameters in beer fermentation. **Journal of Industrial Microbiology**, v. 15, p. 401-406, 1995.
- GERMER, S. P., MOURA, S. C. S. R., LEITÃO, M. F. F. JUNQUEIRA, V. C. A., NETO, R. O. T., GONÇALVES, J. R., JARDIM, D. C. P., VITALI, A. A. **Princípios de Esterilização de Alimentos**. 2ª edição. Campinas: ITAL, 1995. 123p.
- GHANI, A. G., FARID, M. M., CHEN, X. D., RICHARDS, P. Thermal sterilization of canned food in a 3-D pouch using computational fluid dynamics. **Journal of Food Engineering**, v. 48, p.147-156, 2001.
- GOULD, G. W. Methods for preservation and extension of shelf life. **International Journal of Food Microbiology**, v.33, p. 51-64, 1996.
- HORIMOTO, Y., DURANCE, T., NAKAI, S. Neural network vs principal component regression for prediction of wheat flour foaf volume in baking tests. **Journal of Food Science**, v. 60, n. 3, p. 429-433, 1995.
- JINESCU, G., LAVRIC, V. The artificial neural networks and the drying process modeling. **Drying Technology**, v. 13, n. 5-7, p. 1579-1586, 1995.
- KORMENDY, I., MOHÁCSI-FARKAS, C. Heat treatment and the defective units' ratio: surviving active spores in pea puree. **Journal of Food Engineering**, v. 45, p.225-230, 2000.

- LEWIS, M. J., **Propiedades físicas de los alimentos e de los sistemas de procesado.** Editorial Acribia Saragoza España, 1993. 494 p.
- MAFART, P., **Procesos físicos de conservacion.** Editorial Acribia Saragoza España, v.1, 1994. 285p.
- MERIDA RAMOS, F. J., MEDINA GOMEZ, M G., MEJIA ARIAS, C. R., ARIAS FERNANDEZ, M, E.. Inactivacion térmica de microorganismos: aspectos cinéticos. **Alimentaria**, Julho – Agosto p- 19 – 23 , 1997.
- MITTAL, G. S., ZHANG, J. Prediction of temperature and moisture content of frankfurters during thermal processing using neural network. **Meat Science**, v.55, p. 13-24, 2000.
- POVOA, M. E. B., MORAES-SANTOS, T. Effect of heat treatment on the nutritional quality of milk proteins. **Int. Dairy Journal**, v.7, p. 609-612, 1997.
- RAMASWAMY, H. S., ABBATEMARCO, C. THERMAL processing of fruits. In: **Processing fruits: Science and Technology.** Technomic Publishing Co. Inc.1996.
- RODRIGUES, A. D., SCHIMDT, F. L., VITALI, A. A., TEIXEIRA NETO, R. O., TEIXEIRA, A. A., GERMER, S. P. M., SADAHIRA, M. S. Comparação entre técnicas numéricas para a resolução do problema de transferência de calor em alimentos enlatados. **Ciência e Tecnologia de Alimentos**, v. 18, n. 2, p. 230-236, 1998.
- SABLANI, S. S., RAMASWAMY, H.S., PRASHER, S. O. A neural network approach for thermal processing applications. **Journal of Food Process and Preservation**, v.19, p. 283-301 p., 1995.
- SABLANI, S. S., SHAYYA, W. H. Computarization of Stumbo's method of thermal process calculations using neural networks. **Journal of Food Engineering**, v. 47, p. 233-240, 2001.
- SARAIVA, S. H., MINIM, L. A., COIMBRA, J. S. R., ALVARENGA, A.L. B. Artificial neural networks for efficiency prediction of perforated rotating disk contactor.. **V Simpósio Brasileiro de redes neurais. Ed. Antônio de Pádua Braga**, p. 169-179, 1998.
- STUMBO, C. R. **Termobacteriologia en el procesado de alimentos.** Colegio Oficial de Farmacêuticos, Madrid, 1973. 329 p.
- STUMBO, C. R, LONGLEY, R. E. New parameters for process calculation. **Food Technology**, 20(3), 341-345, 1966.
- TEIXEIRA, A. A., TUCKER, G. S. On-line retort control in thermal sterilization of

- canned foods. **Food Control**, v. 8, n.1, p. 13-20, 1997.
- VALLEJO-CORDOBA, B., ARTEAGA, G. E., NAKAI, S. Predicting milk shelf-life based on artificial neural networks and headspace gas chromatographic data. **Journal of Food Science**, v. 60, n. 5, p. 885-888, 1995.
- WIRTH, F. **Tecnología de los embutidos escaldados**. Acribia, S. A., 1992. 237 p.
- ZHANG, Q., REID, J. F., LITCHFIELD, J. B., REN, J., CHANG, S. A prototype neural network supervised control system for *bacillus thuringiensis* fermentations. **Biotechnology and Bioengineering**, v. 43, p. 483-489, 1994.

## **CAPÍTULO 2**

# **MODELAGEM DO PROCESSAMENTO TÉRMICO DE ALIMENTOS**

## RESUMO

Para a modelagem do processamento térmico de alimentos enlatados foi aplicada a técnica de redes neurais, cujo objetivo foi a determinação da temperatura do ponto frio de um produto enlatado a partir das condições iniciais do processo e da temperatura da autoclave. A rede construída teve como variáveis de entrada: o tempo de processo, a temperatura da autoclave e a temperatura do ponto frio para o tempo presente  $t_i$  e tempos anteriores  $t_{i-1}$ ,  $t_{i-2}$ . A variável de saída foi a temperatura no ponto frio no tempo  $t_{i+1}$ . Para o treinamento da rede, um conjunto de dados em função das variáveis operacionais tempo e temperatura foi obtido através do processamento do produto em autoclave vertical. Foram comparadas duas redes treinadas com os algoritmos: *back-propagation through time* e Jordan, sendo que a rede treinada com o primeiro algoritmo teve capacidade de generalização superior. A rede selecionada foi a 5-8-9-1, a qual apresentou excelente capacidade de generalização, com um erro relativo médio de 0,022 entre os valores de F calculados e preditos.

## 1. INTRODUÇÃO

O processamento térmico é uma das principais tecnologias de preservação de alimentos que visa garantir a qualidade final do produto relativa ao risco à saúde do consumidor. A esterilização térmica de alimentos enlatados em autoclaves tem sido um dos métodos de preservação mais utilizados nos últimos duzentos anos (TEIXEIRA e TUCKER, 1997).

A modelagem da operação de esterilização de produtos alimentícios tem grande importância para estudos de otimização do projeto e operação dos equipamentos do processo. Além disso, é de grande importância para a correção de falhas de processamento, como queda na temperatura do autoclave e alteração na temperatura inicial do produto. Embora as técnicas de modelagem matemática, através de aplicações de balanço diferencial de energia térmica em estado não estacionário sejam muito utilizadas, elas requerem informações exatas das propriedades termofísicas do produto. Entretanto, devido à variação da temperatura durante o processo, estes parâmetros não podem ser consideradas constantes, principalmente em alimentos, dificultando assim uma modelagem apropriada.

Enquanto que o uso de modelos fenomenológicos requerem a solução simultânea de um grande número de equações algébricas, muitas vezes não lineares, exigindo processos iterativos que consomem tempo, a solução do modelo baseado na técnica de redes neurais é mais simples e mais rápida, consistindo na solução em série de um número menor de equações algébricas. Evidentemente redes neurais tornam-se mais atrativas para a aplicação em algoritmos de otimização e controle de processos.

Modelos com redes neurais tem a vantagem de não necessitarem do conhecimento da relação entre as variáveis de entrada e saída, e ao invés disso, descobrem essas relações através de sucessivos treinamentos. Redes neurais podem aprender com exemplos, incorporar muitas variáveis, e fornecer respostas adequadas e rápidas para novas informações não apresentadas previamente (SABLANI e SHAYYA, 2001).

A técnica de redes neurais têm se tornado de grande importância no processamento de alimentos e engenharia, sendo utilizada para a resolução de grande variedade de problemas, principalmente em aplicações como controle de processos, interpretação de sensores e modelos dinâmicos (GARCIA et al., 1995).

Os modelos com redes neurais têm sido aplicados como alternativas aos métodos de cálculos para o processamento térmico convencional. SABLANI et al. (1995) utilizaram redes neurais na otimização de processamento térmico. Um algoritmo computacional, baseado na técnica de diferenças finitas foi desenvolvido para gerar dados de tempo-temperatura sob variadas condições de processamento térmico. A letalidade foi determinada considerando as variáveis de entrada (tamanho da lata, difusividade térmica do alimento) para temperaturas variando entre 110 e 134°C. O algoritmo *back-propagation* foi utilizado para treinamento da rede neural. A predição de temperaturas ótimas de esterilização foram obtidas com acuracidade de  $\pm 0,5^\circ\text{C}$ .

AFAGHI et al. (2001) avaliaram modelos de redes neurais artificiais como alternativas para os métodos de cálculos para o processamento térmico convencional. Simulações com modelos matemáticos foram utilizadas para gerar perfis de temperatura em uma ampla faixa de tamanhos de latas sob diferentes condições de operação do processamento térmico. Dados de tempo-temperatura foram empregados para avaliar os parâmetros de penetração de calor,  $f_h$ ,  $j_{ch}$ ,  $f_c$  e  $j_{cc}$  como também computar a letalidade e o tempo de processo. Esses dados foram usados para desenvolver a rede neural. Os métodos de Ball, Stumbo e Pham também foram utilizados para calcular os tempos de processo e as letalidades. A precisão e habilidade dos modelos de redes neurais foram

comparadas com os métodos matemáticos tradicionais. Os resultados dos cálculos de processo do modelo de redes neurais foram equivalentes, e algumas vezes melhores e mais flexíveis que os métodos de Stumbo e Pham.

MITTAL & ZHANG (2000) utilizaram redes neurais para prever a temperatura e a umidade de salsichas durante o tratamento térmico e concluíram ser este um método simples, conveniente e preciso. Teor de gordura, teor inicial de umidade, temperatura inicial, raio da salsicha, temperatura ambiente, umidade relativa e tempo de processo foram as variáveis de entrada. Temperatura no centro da salsicha, temperatura média da salsicha e umidade média contida na salsicha foram as saídas. Os dados de treinamento da rede foram obtidos através de modelos de transferência de calor e massa simulando os perfis de temperatura e umidade da salsicha.

Este trabalho teve como objetivo desenvolver um modelo matemático para o processamento térmico de alimentos enlatados, baseado na técnica de redes neurais. A característica principal do modelo foi prever a temperatura do ponto frio do enlatado ao longo do tempo, a partir das condições iniciais do produto e do processo, e da temperatura da autoclave durante o processamento. Foram estudados e comparados dois algoritmos de treinamento: *back-propagation through time* e Jordan, em relação às suas capacidades de generalização.

## **2. MATERIAIS E MÉTODOS**

O produto utilizado para o processamento térmico foi uma pasta de fígado, composta por 20 % de fígado suíno, 60% de carne suína e 20% de água, preparada em um *cutter* (Mainca, Inglaterra).

Latas cilíndricas de 340 g contendo a pasta de fígado foram processadas em uma autoclave vertical descontínua, utilizando vapor como meio de aquecimento. As latas foram preparadas, instalando-se termopares tipo T no seu centro, a fim de que a temperatura no ponto frio fosse monitorada durante o processo. Logo após o envase e fechamento, as latas foram mantidas em banho térmico para ajuste e homogeneização da sua temperatura inicial. Em seguida, foram acondicionadas lado a lado dentro da autoclave que, após fechada, foi iniciado o processo. Um controlador proporcional-integral (Spirax Sarco, Inglaterra) foi utilizado para controlar a temperatura do processo. Para a tomada de tempo e temperatura foi utilizado um equipamento com sistema de



aquisição de dados *Field Logger* (Novus, Brasil), acoplado aos termopares tipo T. Ao término da esterilização, seguiu-se a etapa de resfriamento, com pressurização com ar para evitar estufamento das latas até temperatura inferior a 100°C. O resfriamento prosseguiu até que a temperatura no ponto frio atingisse 40°C.

A fim de obter um conjunto de dados experimentais em função das variáveis operacionais tempo e temperatura, vários processos foram conduzidos utilizando quatro temperaturas para a autoclave: (113, 117, 121 e 125)°C. Para cada temperatura da autoclave foram testadas três temperaturas iniciais do produto: (25, 35 e 45)°C. Perturbações foram aplicadas na temperatura da autoclave durante o processamento, simulando falhas ocorridas no processo real a (10, 30 e 50) minutos do início do processamento. Todas as perturbações tiveram duração de três minutos e foram realizadas interrompendo a entrada de vapor. O sistema de aquisição de dados registrou o tempo e a temperatura no centro do produto a cada 20 segundos.

O produto foi caracterizado quanto ao: a) teor de gordura, segundo o método de intermitente Soxhlet; b) umidade, segundo o método gravimétrico, c) proteína, segundo o método Kjeldahl (PRICE e SCHWEIGERT, 1994).

Tabela 2.1 – Parâmetros operacionais utilizados na etapa da generalização

experimento	Condições operacionais		
	Temperatura da autoclave (°C)	Temperatura inicial do produto (°C)	Perturbação (min)
A	113	25	10
B	117	45	50
C	121	45	50
D	125	35	30

## 2.1 Modelagem utilizando redes neurais artificiais

O processamento térmico do produto cárnico visou obter um conjunto de dados experimentais em função das variáveis tempo e temperatura para o desenvolvimento de uma estrutura de rede neural.

Para a modelagem do processamento térmico foi aplicada a técnica de redes neurais, para determinar a temperatura do ponto frio no tempo futuro  $t_{i+1}$  em função do tempo, da temperatura da autoclave e da temperatura no ponto frio em tempos atual e passado (definiu-se para este trabalho usar dois intervalos de tempo passado). O parâmetro de saída foi representado pela temperatura no ponto frio no tempo  $t_{i+1}$ . Portanto, a rede construída foi composta de cinco nodos na camada de entrada e um nodo na camada de saída.

Como o processamento térmico apresenta um comportamento que varia com o tempo, a rede adequada para este tipo de processamento é a recorrente (BRAGA et al, 2000). Para a escolha da rede que oferece menor erro de validação foram utilizados dois tipos de redes recorrentes: a *back-propagation through time* (BPTT) (I) e a de Jordan (II).

#### I – Rede *back-propagation through time*

Para o desenvolvimento do modelo desta rede foi empregado um software comercial, NeuralWorks Professional II/ Plus (Neuralware Inc., Pittsburg, PA, USA). Para o treinamento e aprendizagem da rede neural foi usado o algoritmo *back-propagation through time*, que é uma extensão do algoritmo *back-propagation* padrão, onde a saída,  $y_j(t+1)$  ( $j=1, m$ ), é realimentada através de *loops* recorrentes para a camada de entrada,  $y_j(t)$  ( $j=1, m$ ) (BAUGHMAN e LIU, 1995). Para determinar a topologia ótima da rede, tanto a escolha da regra de aprendizagem, quanto o número de camadas intermediárias com seu respectivo número de neurônios, como para os coeficientes de aprendizagem utilizou-se o método de tentativa e erro que resultasse no menor erro de validação.

#### II - Rede do tipo Jordan

Para aprendizagem da rede do tipo Jordan, utilizou-se o simulador SNNS (*Stuttgart Neural Network Simulator*), desenvolvido pelo Instituto de Sistemas Paralelos Distribuídos de Alto Desempenho (IPVR, Stuttgart). Para determinar a topologia ótima da rede empregou-se o método construtivo, ou seja, parte-se de um número pequeno de nodos, e são analisados os valores dos erros à medida que os números de nodos são acrescentados. Com este procedimento foi escolhido o número de camadas intermediárias com seu respectivo número de nodos que resultasse no menor erro de validação.

Para ambos os casos, foi usado um conjunto de 25112 dados obtidos no processamento térmico do produto para treinamento da rede. Simultaneamente, foi realizada a etapa de teste da rede utilizando um conjunto contendo 8968 dados. Esta etapa é importante, uma vez que a sobreparametrização da rede pode ser evitada.

As redes treinadas foram usadas para prever o perfil de temperatura do ponto frio e, conseqüentemente, prever o valor F do processo. Para testar sua generalização, foram empregados um conjunto de 4298 dados não empregados na etapa de treinamento e teste, conforme mostra a Tabela 2.1.

A letalidade dos microorganismos representa o efeito letal de um tratamento térmico a qualquer temperatura. Para o cálculo da letalidade (L) foram usados como temperatura de referência,  $T_{ref}=121,1$  °C e um valor de “z” igual a 10 °C. A expressão para o cálculo da letalidade é dada por (MAFART, 1994):

$$L = 10^{\frac{(T-121,1)}{10}} \quad (1)$$

O valor de F foi calculado pela seguinte integração de L ao longo do tempo, segundo a equação (2):

$$F = \int_{t_0}^{t_f} L dt \quad (2)$$

onde:

$t_f$  é o tempo em minutos no final do processo e  $t_0$  é o tempo em minutos no início do processo

### 3. RESULTADOS E DISCUSSÃO

O processamento térmico do produto cárnico composto por 8,03 % de gordura, 12,3 % de proteína e 72 % de água teve como objetivo gerar dados necessários para o desenvolvimento de uma estrutura de rede neural.

Para a escolha da rede com melhor desempenho em prever o perfil de temperatura para novas condições, o processo de aprendizagem deve alcançar um

conjunto de pesos ótimo da rede. Primeiramente, foram testadas dois tipos de redes a fim de obter um menor erro de validação.

### 3.1 Aprendizagem e treinamento

**I** – Rede *BPTT* - A regra de aprendizagem utilizada foi a regra delta. A função de ativação usada foi a sigmoideal. A função objetivo usada foi a minimização do erro quadrático médio. A topologia da rede que apresentou o menor erro quadrático médio é apresentada na Figura 2.1, e foi composta por duas camadas intermediárias com 8 nodos na primeira camada e 9 nodos na segunda.




Figura 2.1 – Topologia da rede *BPTT*

**II** - Para a aprendizagem da rede do tipo Jordan, foi selecionado o algoritmo de aprendizagem denominado *resilient back-propagation*, o qual apresentou o menor erro de validação em relação aos demais. A função de ativação utilizada foi a sigmoideal. O número de neurônios na camada intermediária foi variado de 2 em 2 até 22, onde a

configuração ótima obtida foi a arquitetura composta por 4 nodos em cada uma das camadas intermediárias. A topologia da rede construída pode ser observada na Figura 2.2.




Figura 2.2 – Topologia da rede do tipo Jordan

A Figura 2.3 apresenta a comparação entre as previsões feitas pelas redes *back-propagation* e Jordan e os valores experimentais do conjunto de validação. Observa-se uma alta correlação entre os valores experimentais e preditos, ao longo de todo o processo, indicando um bom ajuste do modelo neural ao comportamento do processo quando do início do resfriamento, fato este melhor observado na Figura 2.4.

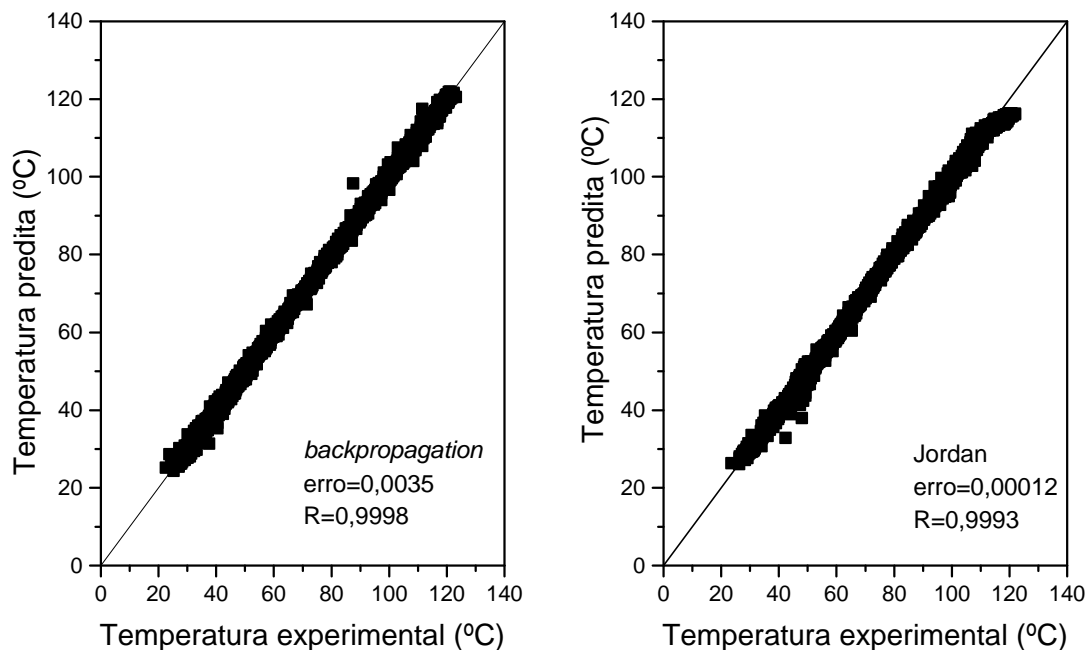


Figura 2.3 – Temperatura predita versus temperatura experimental

A Figura 2.4 apresenta o perfil de temperatura no ponto frio ao longo do tempo, para os processos A, B, C e D da Tabela 2.1. Observa-se uma boa concordância entre os valores experimentais e os preditos pelas redes neurais, embora para os processos C e D, a predição pela rede Jordan tenha apresentado um pequeno desvio. Entretanto, dado que a relação da cinética de destruição com a temperatura ser uma função exponencial, pequenos desvios na temperatura do ponto frio quando esta se aproxima do valor da temperatura de referência, ocasionaram um desvio relativamente grande no valor da letalidade do processo. Este fato é observado na Figura 2.5, que apresenta o valor da letalidade acumulada do processo ao longo do tempo. Pode-se notar claramente a superioridade da rede *backpropagation* em relação à rede Jordan, para predição da temperatura do ponto frio do processamento térmico.

A Tabela 2.2 apresenta os valores de F calculados com os dados de tempo-temperatura experimentais e preditos pelas redes. Nota-se que a rede Jordan desenvolvida neste trabalho apresentou desvios muito elevados. Por outro lado, a rede *backpropagation* apresentou desvios não superiores a 0,0264 do valor de F determinado experimentalmente, o que a torna apropriada para uso como modelo preditivo do processamento térmico de alimentos.

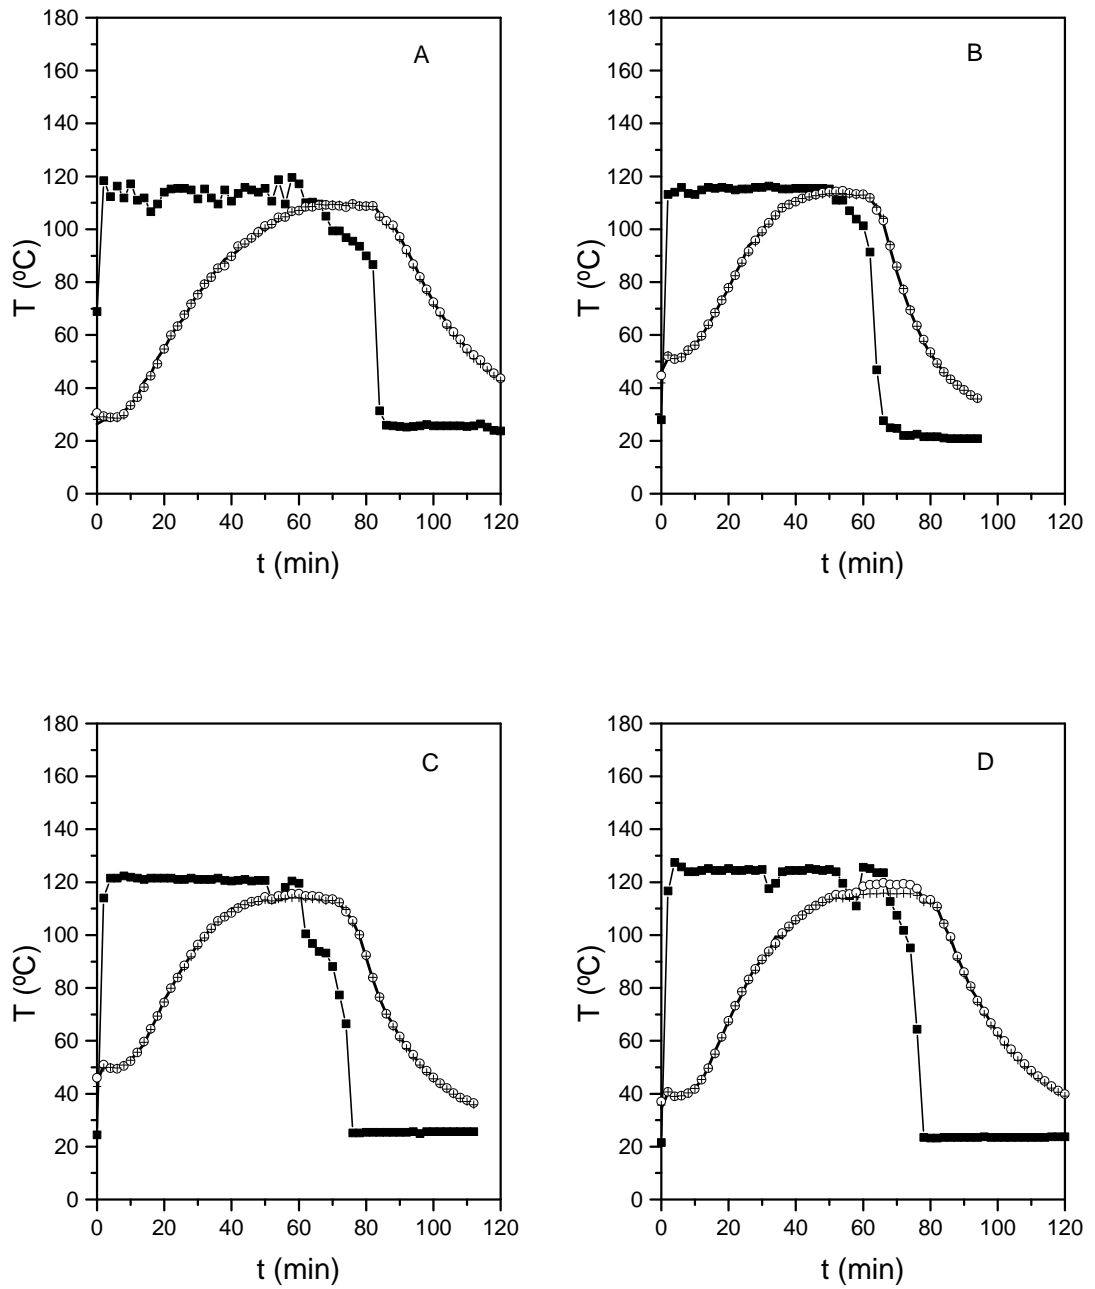


Figura 2.4 – Perfis de temperatura da autoclave e ponto frio ao longo do tempo;

comparação entre dados experimentais e preditos

—■— autoclave    — experimento    ○ predito    + Jordan

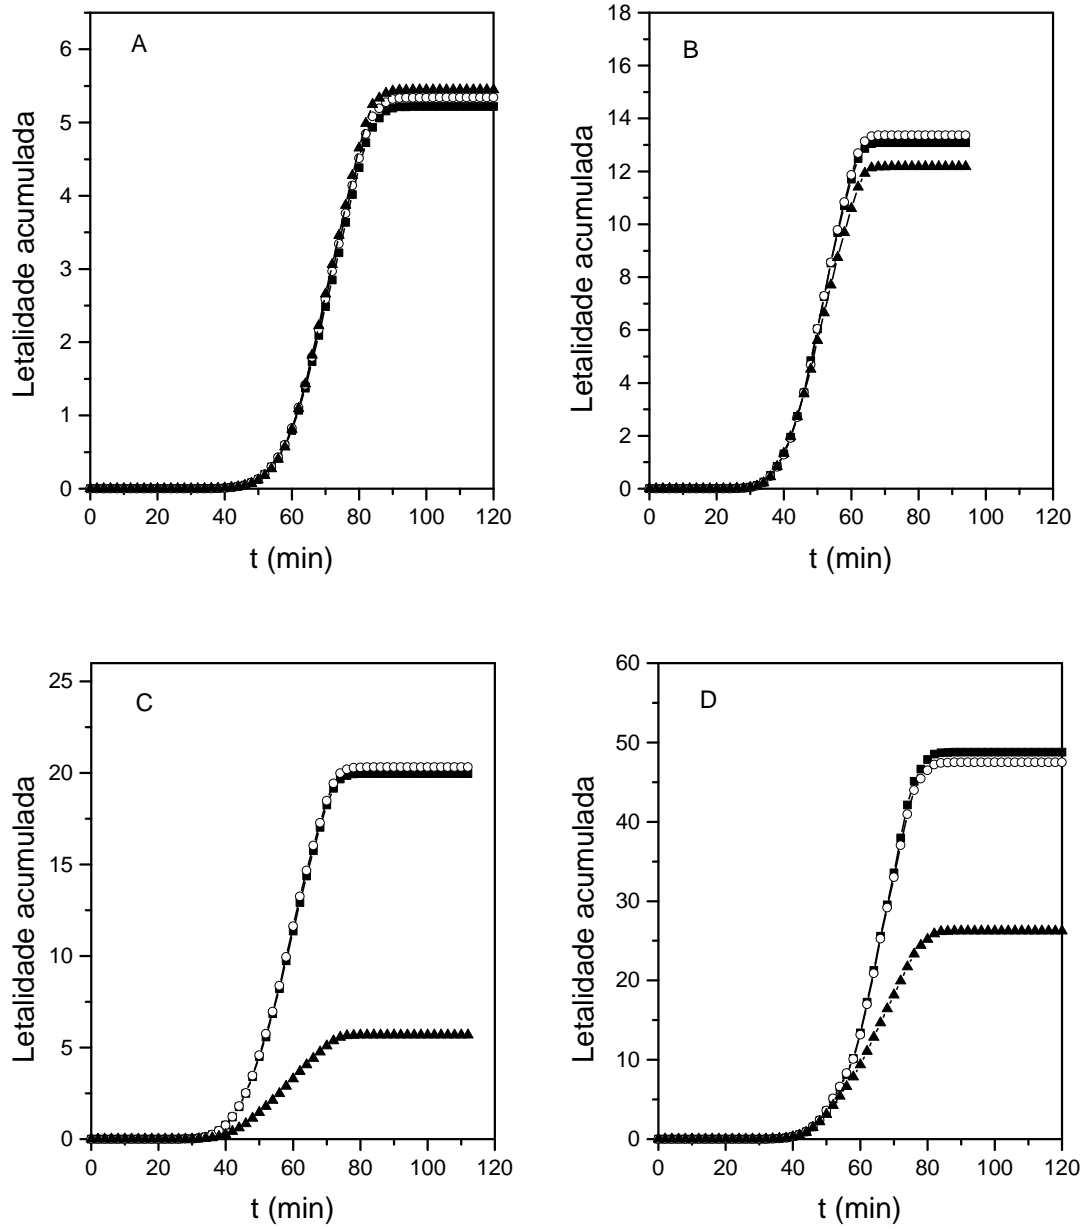


Figura 2.5 – Comparação entre os valores de letalidade acumulada experimental e letalidade acumulada predita.

—■— experimento    —○— *back-propagation*    —▲— Jordan



Tabela 2.2 – Comparação entre valores de F experimentais e preditos

Tipo de rede	experimento	Valores de F		Diferença
		Experimental	Predito	
<i>Back-propagation</i>	A	1,722	1,762	0,0232
	B	4,318	4,411	0,0215
	C	6,591	6,702	0,0168
	D	16,095	15,67	0,0264
Jordan	A	1,722	1,797	0,0436
	B	4,318	4,017	0,0697
	C	6,590	5,624	0,1466
	D	16,095	8,653	0,4624

#### 4. CONCLUSÃO

A rede *BPTT* apresentou melhor desempenho na modelagem do processamento térmico do produto enlatado. Por outro lado, a rede Jordan desenvolvida neste trabalho não foi adequada ao processamento térmico de enlatados, uma vez que apresentou desvios elevados do valor de F.

A topologia de rede 5-8-9-1 foi a que melhor se adequou ao problema em estudo apresentando excelente capacidade de generalização para novas condições de processo, bem como situações de perturbações na temperatura da autoclave, com um erro relativo médio de 0,022.

Redes neurais demonstraram grande potencial para a modelagem do processamento térmico de alimentos, com vantagens como precisão e simplicidade já que não requerem informações exatas das propriedades termofísicas do produto e podem fornecer respostas adequadas e rápidas para novas informações não apresentadas previamente.

#### 5. REFERÊNCIAS BIBLIOGRÁFICAS

AFAGHI, M., RAMASWAMY, H. S., PRASHER, S. O. Thermal process calculations using artificial neural network models. **Food Research International**, v. 34, p. 55-

65, 2001.

- BAUGHMAN, D. R., LIU, Y. A. **Neural Networks in bioprocessing and chemical engineering**. San Diego, California:Academic Press, 1995. 488p.
- BRAGA, A. P., CARVALHO, A. P. L. F.,LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. **Editora LTC**, 2000. 262 p.
- GARCIA, L., ARGUESO, F., GARCIA, A., DIAZ, M. Application of neural networks for controlling and predicting quality parameters in beer fermentation. **Journal of Industrial Microbiology**, v. 15, p. 401-406, 1995.
- MAFART, P., **Procesos fisicos de conservacion**. **Editorial Acribia Saragoza España**, v.1, 1994. 285p.
- MITTAL, G. S., ZHANG, J. Prediction of temperature and moisture content of frankfurters during thermal processing using neural network. **Meat Science**, v.55, p. 13-24, 2000.
- PRICE, J. F., SCHWEIGERT, B. S. **Ciência de la carne y de los productos cárnicos**. Acribia, S. A., 1994. 581 p.
- SABLANI, S. S., RAMASWAMY, H.S., PRASHER, S. O. A neural network approach for thermal processing applications. **Journal of Food Process and Preservation**, v.19, p. 283-301, 1995.
- SABLANI, S. S., SHAYYA, W. H. Computarization of Stumbo's method of thermal process calculations using neural networks. **Journal of Food Engineering**, v.47, p. 233-240, 2001.
- TEIXEIRA, A. A., TUCKER, G. S. On-line retort control in thermal sterilization of canned foods. **Food Control**, v. 8, n.1, p. 13-20, 1997.

## **CAPÍTULO 3**

# **ANÁLISE COMPARATIVA ENTRE TÉCNICAS PARA A PREDIÇÃO DA TEMPERATURA DURANTE O PROCESSAMENTO TÉRMICO DE ALIMENTOS ENLATADOS**

## RESUMO

Este trabalho teve como objetivo desenvolver um modelo matemático usando a técnica de redes neurais e comparar com dois métodos tradicionais existentes para o cálculo do processamento térmico de alimentos enlatados. A rede construída teve como variáveis de entrada: o tempo de processo, a temperatura da autoclave e a temperatura ponto frio para o tempo presente e dois intervalos de tempos anteriores. A variável de saída foi a temperatura no ponto frio ao longo do tempo. Para o treinamento da rede, um conjunto de dados em função das variáveis operacionais tempo e temperatura foi obtido através do processamento do produto em autoclave vertical. A rede selecionada foi a rede (5-8-9-1), a qual apresentou excelente capacidade de generalização, com um erro relativo médio de 0,022. A precisão e habilidade do modelo de redes neurais foram comparadas aos dos métodos de Ball e Stumbo, ambas com respeito ao valor de F do processo, demonstrando a superioridade da abordagem neural.

## 1. INTRODUÇÃO

Os métodos existentes envolvendo a solução do cálculo do processamento térmico têm sido usados extensivamente na indústria de alimentos com o propósito de estimar a letalidade de um dado processo, ou alternativamente para determinar um tempo de processo apropriado a partir de um conjunto de condições de aquecimento.

BIGELOW et al. (1920) introduziram um procedimento gráfico para avaliar a eficiência do processamento térmico de alimentos. Esta técnica foi a base de um grupo de metodologias de cálculos de processamentos, que mais tarde foram chamados métodos “gerais”. Os métodos gerais integram os efeitos letais graficamente ou através de integração numérica baseados nos dados de tempo-temperatura. Estes métodos são os mais precisos, pois utilizam dados reais de tempo-temperatura para cálculos de processos. Contudo, a aplicação deste método pode consumir tempo, pois para cada variação nas condições de processo, produto ou tamanho de lata, um novo conjunto de dados de tempo-temperatura é requerido. Métodos matemáticos, por outro lado, são baseados na caracterização dos parâmetros de penetração de calor como índice da taxa de aquecimento ( $f_h$ ) e fatores lag de aquecimento/resfriamento ( $j_{ch}/j_{cc}$ ) para cinética de

destruição. Estes métodos são menos restritivos que o método geral e podem acomodar variações no produto, equipamento e parâmetros de processo (STUMBO, 1973)

O método de Ball desenvolvido em 1923 é uma das técnicas mais usadas para o cálculo do processamento térmico. O cálculo do tempo de processamento ( $B$ ), a uma dada temperatura da autoclave, é baseado na equação matemática a seguir (SABLANI e SHAYYA, 2001):

$$B=f_h[\log(j_{ch}\cdot I)-\log(g)] \quad (1)$$

onde:

$f_h$  é o índice da taxa de aquecimento (min)

$j_{ch}$  é o fator lag da taxa de aquecimento,  $j_{ch}=(T_1-T_a)/(T_1-T_0)$

$T_1$  é a temperatura da autoclave

$T_a$  é o intercepto da linha reta da primeira curva de aquecimento com o eixo da escala logarítmica situada no tempo corrigido

$T_2$  é temperatura do meio de resfriamento

$T_0$  é temperatura inicial do produto

$g$  é a diferença entre a temperatura da autoclave e a temperatura no ponto frio no final do aquecimento

$I$  é a diferença entre a temperatura da autoclave e a temperatura inicial do produto

Dados de penetração de calor são organizados de modo que o logaritmo da diferença entre a temperatura da autoclave e a temperatura no ponto frio durante o aquecimento seja representada contra o tempo em um gráfico semi-logarítmico. Após uma fase lag inicial hiperbólica, o processo de aquecimento é denotado por uma linha reta. O tempo requerido para a porção da parte reta da curva de aquecimento atravessar um ciclo logarítmico é o parâmetro do efeito da temperatura do aquecimento,  $f_h$ , e o fator lag é  $j_{ch}$ . A curva de resfriamento é construída do mesmo modo, onde o logaritmo da diferença entre a temperatura do produto no ponto frio e a temperatura da água de resfriamento é representada contra o tempo, após interromper a alimentação de vapor e o produto iniciar o resfriamento. O parâmetro do efeito da temperatura do resfriamento,  $f_c$ , e o fator lag de resfriamento,  $j_{cc}$ , são calculados de maneira similar ao  $f_h$ , e  $j_{ch}$ . A letalidade e o tempo de processo são obtidos usando as condições de processamento (temperatura da autoclave e temperatura inicial) e tabelas ou gráficos de parâmetros

relacionados ( $f_h/U$  e  $g$ ). As considerações mais significativas feitas no desenvolvimento dessas tabelas e gráficos foram igualar o fator lag de resfriamento ( $j_{cc}$ ) a 1.41 e a taxa de aquecimento à de resfriamento ( $f_h=f_c$ ). Evidentemente, para desvios de processo com essas considerações, o método de Ball é inexato. Assim procedimentos adicionais têm sido desenvolvidos para superar as limitações e considerações empregadas no método de Ball (AFAGUI et al., 2001, GERMER et al., 1995).

Revisando o método de Ball para aumentar sua precisão, Stumbo e Longley (1966) apud AFAGUI et al.(2001) publicaram uma nova série de tabelas acomodando a variabilidade com respeito ao parâmetro  $j_{cc}$ . O procedimento para o cálculo do tempo de processamento e letalidade neste método é similar ao método de Ball no sentido que se baseia em curvas de aquecimento e resfriamento e assume que  $f_h$  é igual a  $f_c$  (AFAGHI et al., 2001). O método de Stumbo eliminou algumas simplificações como o fator lag de resfriamento ( $j_{cc}$ ) igual a 1.41 utilizada no desenvolvimento do método de Ball. Ao invés de confiar em apenas uma tabela, Stumbo desenvolveu 57 tabelas cobrindo uma ampla faixa de valores de  $z$  (-13,3 a 93,3 °C) e fatores lag de resfriamento,  $j_{cc}$ , (0,4 – 2,0) que permitem estimar o tempo de processamento depois de estabelecer a diferença entre as temperaturas do meio de aquecimento e no ponto frio no final do aquecimento (valor  $g$ ). O desenvolvimento das tabelas é também útil em prever a letalidade do processo depois de estabelecer a razão entre a taxa de aquecimento ( $f_h$ ) e o valor de esterilização ( $F$ ) de um processo térmico. Embora preciso, o método de Stumbo é de difícil cálculo já que envolve 57 tabelas comparado ao método de Ball, onde apenas uma tabela é utilizada. Este fato explica a aplicação limitada do método de Stumbo na indústria de alimentos (SABLANI e SHAYYA, 2001).

O método de Stumbo para o cálculo do tempo de processamento ( $B$ ), a uma dada temperatura da autoclave, é baseado na equação matemática desenvolvida por Ball (Equação 1). Com exceção de  $g$  todos os parâmetros da equação 1 podem ser obtidos através da curva de penetração de calor. Na prática,  $g$  pode ser encontrado através das tabelas que relacionam  $g$  a  $f_h/F$  para valores específicos  $z$  e  $j_{cc}$  (obtido da curva de resfriamento). O parâmetro  $F$  representa o tempo de processo equivalente em minutos a uma dada temperatura de referência para um valor selecionado de  $z$ . Nos processos de esterilização, geralmente, a temperatura de referência é de 121,1°C e o valor de  $z$  igual a 10° C.

Enquanto que o uso de modelos fenomenológicos requerem a solução simultânea de um grande número de equações algébricas, muitas vezes não lineares, exigindo processos iterativos que consomem tempo, a solução do modelo baseado na técnica de redes neurais é mais simples e mais rápida, consistindo na solução em série de um número menor de equações algébricas. Evidentemente redes neurais tornam-se mais atrativas para a aplicação em algoritmos de otimização e controle de processos.

A rede neural é um sistema de neurônios ligados por conexões sinápticas que é dividido em neurônios de entrada, que recebem estímulos do meio externo, neurônios internos ou ocultos e neurônios de saída, que se comunicam com o exterior. Os neurônios internos são de grande importância na rede neural, por serem responsáveis pela maior parte do processamento, através das conexões ponderadas; podem ser considerados extratores de características. Os neurônios de saída apresentam o resultado final. Pode-se dizer que uma rede é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Normalmente, essas unidades são conectadas por canais de comunicação que estão associados a determinado peso. O comportamento inteligente de uma rede neural artificial vem das interações entre as unidades de processamento da rede (FILHO, 1996; BARRETO, 1997).

Os modelos neurais têm sido aplicados como alternativas para os métodos de cálculos para o processamento térmico convencional. AFAGHI et al. (2001) avaliaram a aplicação de redes neurais como alternativas aos métodos de cálculos para o processamento térmico convencional. Simulações com modelos fenomenológicos foram utilizadas para gerar perfis de tempo-temperatura, em uma ampla faixa de tamanhos de latas sob diferentes condições de operação do processamento térmico, foram empregados para avaliar os parâmetros de penetração de calor,  $f_h$ ,  $j_{ch}$ ,  $f_c$  e  $j_{cc}$  como também computar a letalidade e o tempo de processo. Esses dados foram usados para desenvolver a rede neural. Os métodos de Ball, Stumbo e Pham também foram aplicados no cálculo dos tempos de processo e as letalidades. A precisão e habilidade dos modelos neurais foram comparadas com os métodos matemáticos, ambos com respeito ao tempo de processo e a letalidade partindo de dados do modelo fenomenológico como referência. Os resultados dos cálculos de processo do modelo neural foi equivalente, e algumas vezes melhor e mais flexível que os métodos de Stumbo e Pham. SABLANI et al. (1995) utilizaram redes neurais na otimização de processos, onde um algoritmo computacional, baseado no modelo fenomenológico foi desenvolvido para prever o efeito de temperatura em alimentos sob variadas condições

de processamento térmico. As letalidades dos processos térmicos foram obtidos para uma faixa de variáveis de entrada (tamanho da lata, difusividade térmica do alimento e parâmetros cinéticos de fatores de qualidade) para temperaturas de esterilização entre 110 e 134°C (com intervalos de 2°C). O algoritmo de *back-propagation* foi utilizado para treinamento da rede neural. A rede neural treinada apresentou uma boa capacidade de generalização, uma vez que a predição de temperaturas ótimas de esterilização foram obtidas com acuracidade de  $\pm 0.5^\circ\text{C}$ .

Este trabalho teve como objetivo desenvolver um modelo matemático usando a técnica de redes neurais como alternativa potencial aos métodos existentes para o cálculo de processamento térmico. O modelo teve como característica principal prever a temperatura do ponto frio do enlatado ao longo do tempo, a partir das condições iniciais do produto e do processo, e da temperatura da autoclave durante o processamento, e sua eficiência foi testada e comparada contra os métodos de Ball e Stumbo.

## **2. MATERIAIS E MÉTODOS**

O produto utilizado para o processamento térmico foi uma pasta de fígado, composta por 20 % de fígado suíno, 60% de carne suína e 20% de água, preparada em um *cutter* (Mainca, Inglaterra).

Latas cilíndricas de 340 g contendo a pasta de fígado foram processadas em uma autoclave vertical descontínua, utilizando vapor como meio de aquecimento. As latas foram preparadas, instalando-se termopares tipo T no seu centro, a fim de que a temperatura no ponto frio fosse monitorada durante o processo. Logo após o envase e fechamento, as latas foram mantidas em banho térmico para ajuste e homogeneização da sua temperatura inicial. Em seguida, foram acondicionadas lado a lado dentro da autoclave que, após fechada, foi iniciado o processo. Um controlador proporcional-integral (Spirax Sarco, Inglaterra) foi utilizado para controlar a temperatura do processo. Para a tomada de tempo e temperatura foi utilizado um equipamento com sistema de aquisição de dados *Field Logger* (Novus, Brasil), acoplado aos termopares tipo T. Ao término da esterilização, seguiu-se a etapa de resfriamento, com pressurização com ar para evitar estufamento das latas até temperatura inferior a 100°C. O resfriamento prosseguiu até que a temperatura no ponto frio atingisse 40°C.



A fim de obter um conjunto de dados experimentais em função das variáveis operacionais tempo e temperatura, vários processos foram conduzidos utilizando quatro temperaturas para a autoclave: (113, 117, 121 e 125)°C. Para cada temperatura da autoclave foram testadas três temperaturas iniciais do produto: (25, 35 e 45)°C. Perturbações foram aplicadas na temperatura da autoclave durante o processamento, simulando falhas ocorridas no processo real a (10, 30 e 50) minutos do início do processamento. Todas as perturbações tiveram duração de três minutos e foram realizadas interrompendo a entrada de vapor. O sistema de aquisição de dados registrou o tempo e a temperatura no centro do produto a cada 20 segundos.

O produto foi caracterizado quanto ao: a) teor de gordura, segundo o método de intermitente Soxhlet; b) umidade, segundo o método gravimétrico, c) proteína, segundo o método Kjeldahl (PRICE e SCHWEIGERT, 1994).

## **2.1 Modelagem utilizando redes neurais artificiais**

O processamento térmico do produto cárnico foi realizado a fim de obter um conjunto de dados experimentais em função das variáveis tempo e temperatura para o desenvolvimento e treinamento de uma rede neural.

Para a modelagem do processamento térmico foi usada uma rede recorrente, do tipo *back-propagation through time* (BPTT). As variáveis de entrada foram: o tempo de processo, a temperatura da autoclave e a temperatura do ponto frio para o tempo presente  $t_i$  e tempos anteriores  $t_{i-1}$ ,  $t_{i-2}$ . O parâmetro de saída foi representado pela temperatura no ponto frio no tempo  $t_{i+1}$ . Portanto, a rede construída foi composta de cinco nodos na camada de entrada e um nodo na camada de saída.

Para o desenvolvimento do modelo desta rede foi empregado um software comercial, NeuralWorks Professional II/ Plus (Neuralware Inc., Pittsburg, PA, USA). Para determinar a topologia ótima da rede, tanto a escolha da regra de aprendizagem, quanto o número de camadas intermediárias com seu respectivo número de neurônios, como para os coeficientes de aprendizagem utilizou-se o método de tentativa e erro que resultasse no menor erro de validação.

Na etapa de treinamento, foi usado um conjunto de 25112 dados obtidos no processamento térmico do produto Simultaneamente ao treinamento, foi realizada a

etapa de teste da rede utilizando um conjunto contendo 8968 dados. Esta etapa é importante, uma vez que a sobreparametrização da rede pode ser evitada.

Na etapa de generalização, um conjunto contendo 4298 dados de tempo-temperatura, foi usado para testar o desempenho da mesma.

A letalidade dos microorganismos representa o efeito letal de um tratamento térmico a qualquer temperatura. Para o cálculo da letalidade (L) foram usados como temperatura de referência,  $T_{ref}=121.1$  °C e um valor de “z” igual a 10 °C. A expressão para o cálculo da letalidade é dada por (MAFART, 1994):

$$L = 10^{\frac{(T-121.1)}{10}} \quad (2)$$

O valor de F foi calculado pela seguinte integração de L ao longo do tempo, segundo a equação (3):

$$F = \int_{t_o}^{t_f} L dt \quad (3)$$

onde:

$t_f$  é o tempo em minutos no final do processo e  $t_o$  é o tempo em minutos no início do processo

A eficiência do modelo desenvolvido a partir da técnica de redes neurais foi testada e comparada com os resultados obtidos pelos métodos de Ball e Stumbo. O cálculo do tempo de processamento (B), a uma dada temperatura da autoclave foi baseado na equação (1).

### 3. RESULTADOS E DISCUSSÃO

O processamento térmico do produto cárnico composto por 8,0 % de gordura, 12,3 % de proteína e 72,0 % de água teve como objetivo gerar dados necessários para o desenvolvimento de uma estrutura de rede neural.

#### 3.1 Aprendizagem e treinamento

Para o treinamento e aprendizagem da rede neural utilizou-se o algoritmo *back-propagation through time*. A função de ativação usada foi a sigmoideal. A função

objetivo usada foi a minimização do erro quadrático médio. A topologia da rede que apresentou o menor erro quadrado médio é apresentada na Figura 3.1, e foi composta por duas camadas intermediárias com 8 nodos na primeira camada e 9 nodos na segunda.




Figura 3.1 – Topologia da rede *back-propagation through time*

A análise entre as previsões feitas pela rede *back-propagation* e os valores experimentais da temperatura no ponto frio, ao longo do tempo, pode ser observada na Figura 3.2. Observa-se uma boa concordância entre os valores experimentais e preditos ao longo de todo o processo, demonstrando sua habilidade em prever a temperatura no ponto frio nas etapas de aquecimento e resfriamento.

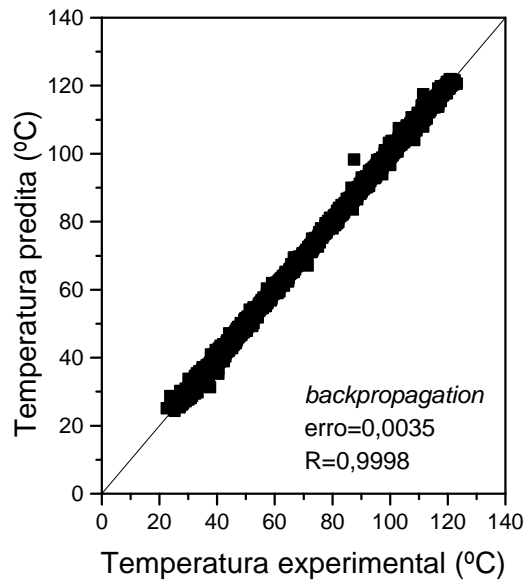


Figura 3.2 – Temperatura predita versus temperatura experimental

A Figura 3.3 apresenta o perfil de temperatura no ponto frio ao longo do tempo, para os processos A, B e C da Tabela 3.1. Observa-se uma boa concordância entre os valores experimentais e os preditos pelas redes neurais. Entretanto, dado que a relação da cinética de destruição com a temperatura ser uma função exponencial, pequenos desvios na temperatura do ponto frio quando esta se aproxima do valor da temperatura de referência, ocasionaram um desvio maior no valor da letalidade do processo. Este fato é observado na Figura 3.4, que apresenta o valor da letalidade acumulada do processo ao longo do tempo.

A Tabela 3.2 apresenta os valores da letalidade do processo (F) calculados com os dados de tempo-temperatura experimentais e pelos métodos de redes neurais artificiais, Ball e Stumbo. Nota-se que a rede *back-propagation* desenvolvida neste trabalho apresentou desvios não superiores a 2,26% do valor de F determinado experimentalmente, o que a torna apropriada para uso como modelo preditivo do processamento térmico de alimentos. Por outro lado, observou-se que os métodos de Ball e Stumbo apresentaram erros superiores. Pode-se notar a partir desses resultados a superioridade da técnica de redes neurais em relação aos métodos de Ball e Stumbo, para predição do valor de F.

Tabela 3.1 – Parâmetros operacionais utilizados na etapa da generalização

experimento	Condições operacionais		
	Temperatura da autoclave (°C)	Temperatura inicial do produto (°C)	Perturbação (min)
A	113	25	10
B	117	45	50
C	121	45	50

Tabela 3.2 – Comparação entre os valores de F experimentais e preditos

experimento	Valores de F			Diferença entre valores de F (%)			
	experimental	Método de Ball	Método de Stumbo	Redes neurais	Método de Ball	Método de Stumbo	Redes neurais
A	1,722	1,4902	1,618	1,762	13,46	6,04	2,26
B	4,318	3,940	4,529	4,411	8,74	4,66	2,12
C	6,591	6,982	6,891	6,702	5,60	4,37	1,66

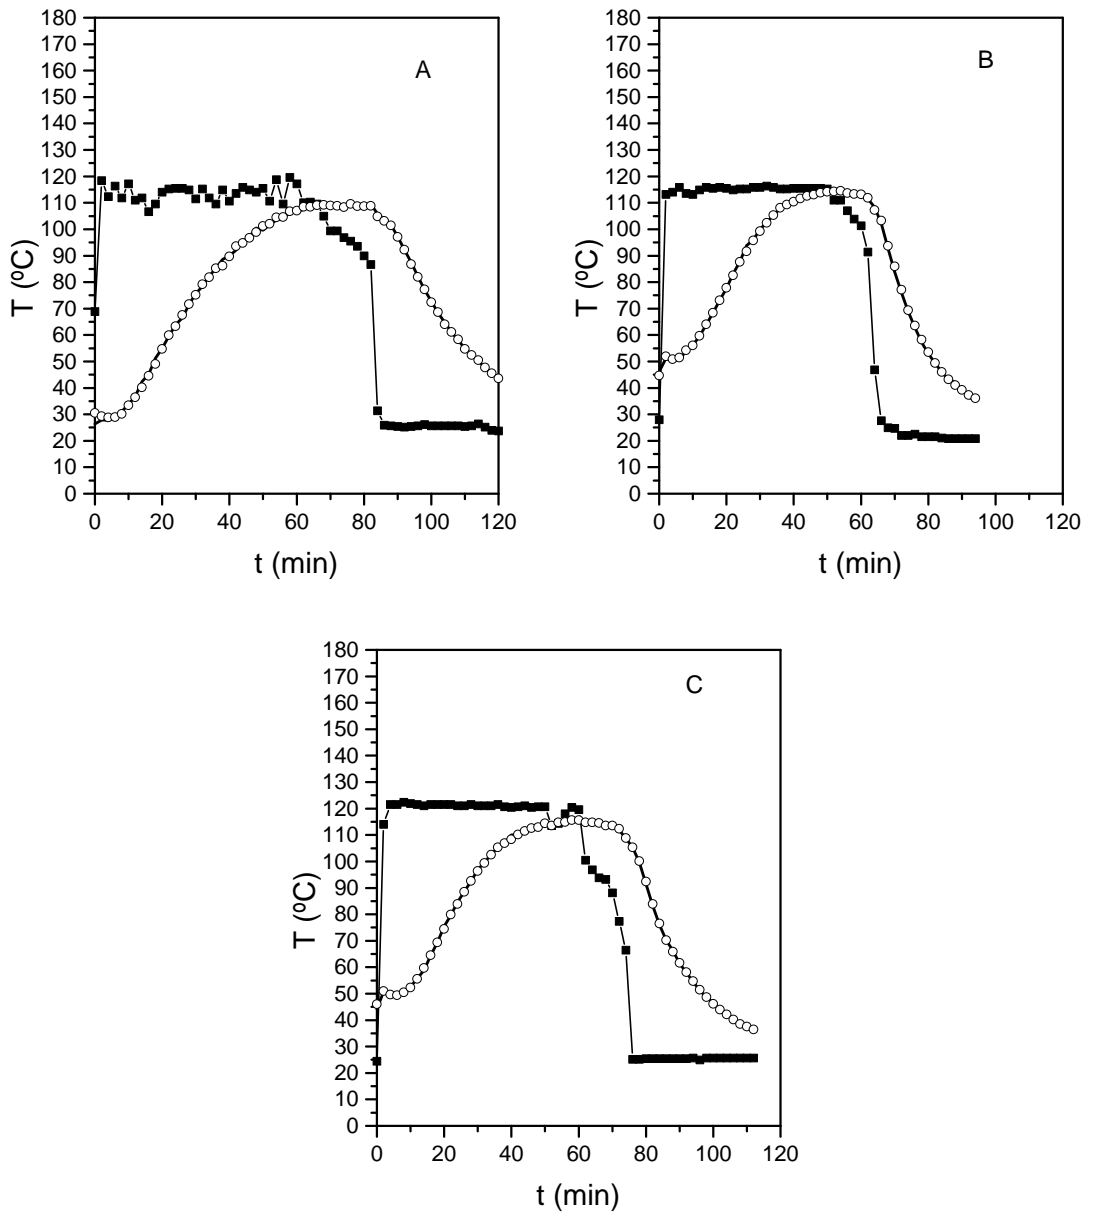


Figura 3.3 – Temperatura na autoclave e centro do produto ao longo do tempo, comparação entre dados experimentais e preditos pela rede neural para o processo completo

—■— autoclave    —■— experimento    ○ predito

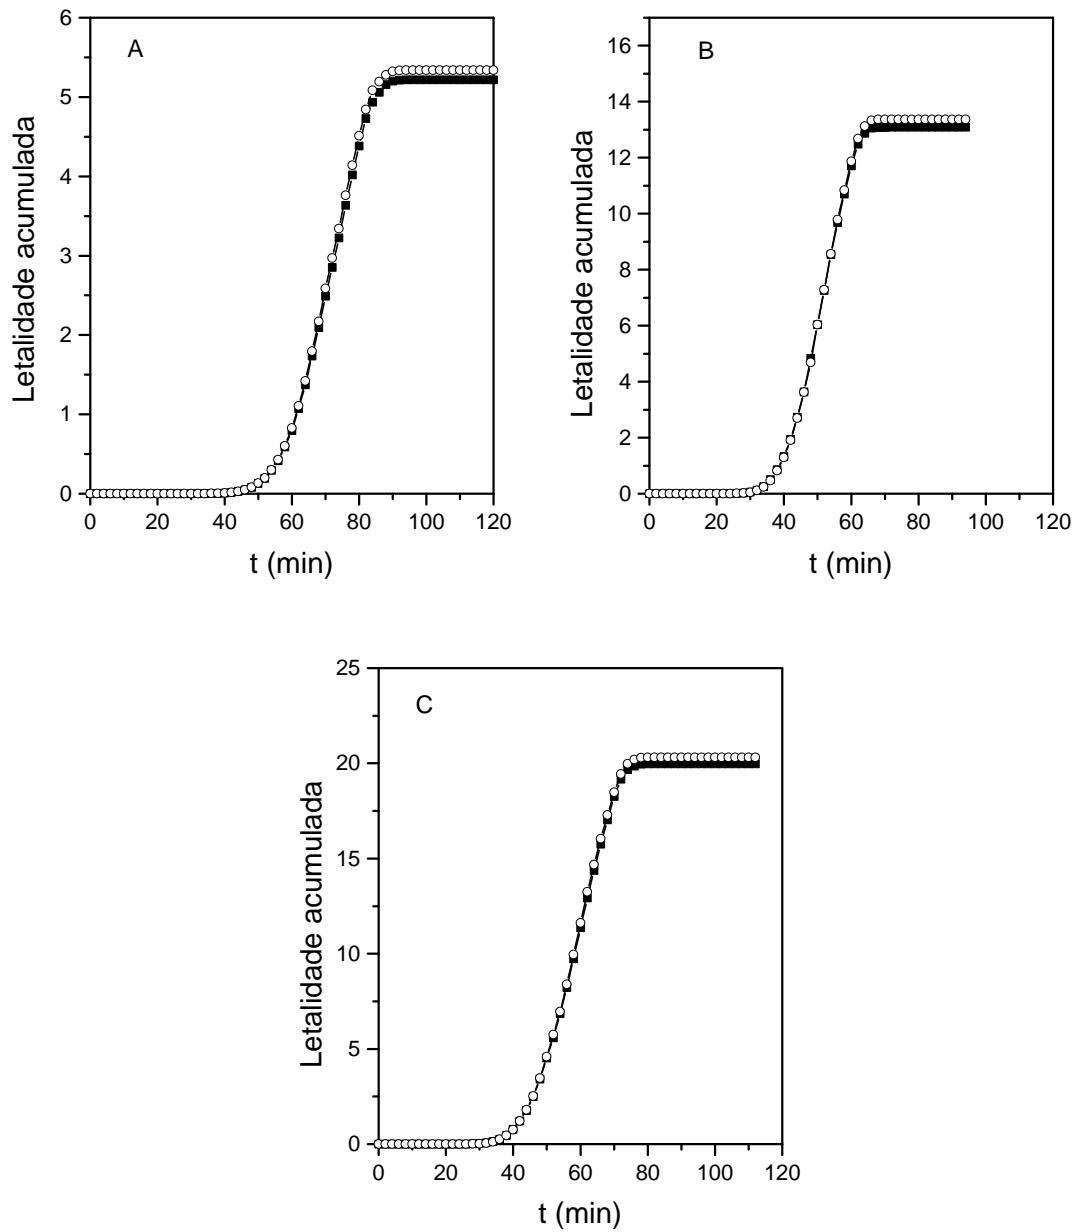


Figura 3.4 – Comparação entre os valores de letalidade acumulada experimental e predita pela rede neural.

—■— experimento    ○    predito

#### 4. CONCLUSÃO

No presente trabalho foi estudada a possibilidade do desenvolvimento de um modelo neural como uma alternativa aos métodos existentes para o cálculo de processamento térmico.

A topologia de rede 5-8-9-1 foi a que melhor se adequou ao problema em estudo apresentando excelente capacidade de generalização para novas condições de processo, bem como situações de perturbações na temperatura da autoclave, com um erro relativo médio de 0,022.

O modelo de rede neural apresentou melhor desempenho na predição do valor de F em relação aos métodos de Ball e de Stumbo.

Os modelos de redes neurais demonstraram grande potencial como alternativa para os métodos de cálculos para o processamento térmico convencional com vantagens como precisão e simplicidade.

#### 5. REFERÊNCIAS BIBLIOGRÁFICAS

- AFAGHI, M., RAMASWAMY, H. S., PRASHER, S. O. Thermal process calculations using artificial neural network models. **Food Research International**, v. 34, p. 55-65, 2001.
- BARRETO, J. M. Introdução às redes neurais artificiais. **Anais da V Escola de Informática da SBC Regional Sul**, p. 41-71, 1997.
- BIGELOW, W. C., BOHART, G. S., RICHARDSON, A. C., BALL, O., F. C. Heat penetration in processing canned foods. **National Canners Association**, 1920. 16L.
- FILHO, E. C. B. C. Modelagem, aplicações e implementações de redes neurais. **Anais da IV escola Regional de Informática da SBC Regional Sul**, p. 36-53, 1996.
- GERMER, S. P., MOURA, S. C. S. R., LEITÃO, M. F. F. JUNQUEIRA, V. C. A., NETO, R. O. T., GONÇALVES, J. R., JARDIM, D. C. P., VITALI, A. A. **Princípios de Esterilização de Alimentos**. 2ª edição. Campinas: ITAL, 1995. 123p.
- MAFART, P., **Procesos físicos de conservacion**. Editorial Acribia Saragoza España, v.1, 1994. 285p.
- PRICE, J. F., SCHWEIGERT, B. S. **Ciência de la carne y de los productos cárnicos**. Acribia, S. A., 1994. 581 p.
- SABLANI, S. S., RAMASWAMY, H.S., PRASHER, S. O. A neural network approach



- for thermal processing applications. **Journal of Food Process and Preservation**, v.19, p. 283-301 p., 1995.
- SABLANI, S. S., SHAYYA, W. H. Computerization of Stumbo's method of thermal process calculations using neural networks. **Journal of Food Engineering**, v. 47, p. 233-240, 2001.
- STUMBO, C. R. **Termobacteriologia en el procesado de alimentos**. Colegio Oficial de Farmacêuticos, Madrid, 1973. 329 p.
- STUMBO, C. R, LONGLEY, R. E. New parameters for process calculation. **Food Technology**, 20(3), 341-345, 1966.

## **CAPÍTULO 4**

# **DESENVOLVIMENTO DE NOVA METODOLOGIA PARA DEFINIÇÃO DO PROCESSAMENTO TÉRMICO DE ALIMENTOS: APLICAÇÃO DE REDES NEURAIIS**

## RESUMO

A técnica de redes neurais foi usada para a modelagem do processamento térmico de alimentos enlatados. Uma rede *back-propagation through time* foi desenvolvida, tendo como variáveis de entrada o tempo de processo, a temperatura da autoclave e a temperatura do ponto frio para o tempo  $t_i$ ,  $t_{i-1}$  e  $t_{i-2}$ . A variável de saída foi a temperatura no ponto frio no tempo  $t_{i+1}$ . Para o treinamento da rede, um conjunto de dados em função das variáveis operacionais tempo e temperatura foi obtido através do processamento do produto em autoclave vertical. A rede selecionada foi a 5-8-9-1, a qual apresentou excelente capacidade de generalização, com um erro relativo médio de 0,022 entre os valores de F calculados e preditos. Na etapa de resfriamento, uma rede *back-propagation* foi desenvolvida com o objetivo de prever a contribuição do resfriamento sobre o valor de F do processo para diferentes valores de temperatura no centro do produto no início e no final do resfriamento e da temperatura da água de resfriamento. A rede desenvolvida teve como variáveis de entrada: a temperatura do centro do produto no início do resfriamento, a temperatura da água de resfriamento e a temperatura do ponto frio no final do resfriamento. A variável de saída foi o valor de F. Para o treinamento da rede, um conjunto de dados em função das variáveis operacionais tempo e temperatura foi obtido através do processamento do produto em autoclave vertical. A rede selecionada para a etapa de resfriamento foi a rede (5-14-10-1) e apresentou boa capacidade de generalização, com um erro relativo médio de 0,706.

## 1. INTRODUÇÃO

Modelos matemáticos desenvolvidos para solução do problema de transferência de calor em alimentos envasados têm sido aplicados com sucesso na otimização e controle de processos (TEIXEIRA e TUCKER, 1997). A principal característica desses modelos é a predição do perfil de temperatura baseado em equações de transferência de calor. Esses modelos requerem o conhecimento de parâmetros físicos como a difusividade térmica do produto, capacidade térmica, coeficiente de transferência de calor do meio de aquecimento e resfriamento. Devido a habilidade em obter resultados precisos de tempo-temperatura, estes modelos substituíram amplamente a necessidade

de executar experimentos para obter dados de rotina quando as condições de contorno são bem definidas (AFAGUI et al., 2001).

TEIXEIRA e BALABAN (1996) desenvolveram um algoritmo baseado no modelo fenomenológico para aplicação no controle em tempo real de processos térmicos em autoclave, incluindo os problemas causados por desvios de processo, o que é solucionado de modo pouco preciso e trabalhoso pelos métodos tradicionais.

TEIXEIRA e TUCKER (1997) revisaram os vários estudos que foram feitos nos últimos anos para a realização do controle *on line* para o tratamento térmico de alimentos enlatados em autoclaves. Este tipo de controle requer o conhecimento do perfil da temperatura do centro do produto enquanto desenvolve o tempo excedente em resposta a toda variação que ocorrer na temperatura da autoclave. Isto é realizado inserindo termopares nos recipientes junto a um sistema de aquisição de dados de tempo real no controle do processo. Na maioria dos casos, entretanto, este método seria pouco prático e com custo elevado. O uso de fatores de correção como meios de ajuste do processo para compensar os desvios não programados são aproximações que não têm flexibilidade, e geralmente resultam em superprocessamento desnecessário. Modelos matemáticos fenomenológicos capazes de prever a temperatura no centro do produto em resposta a toda variação na temperatura da autoclave têm demonstrado grande potencial para o uso de sistema de controle *on line*.

Ainda que a capacidade de modelos matemáticos de transferência de calor de simular o processamento térmico seja reconhecida, requerem informações exatas das propriedades termofísicas do produto, que são ainda dificultadas pela alteração constante dos parâmetros do processo.

Redes neurais têm a vantagem de não necessitarem do conhecimento da relação entre as variáveis de entrada e saída, e ao invés disso, descobrem essas relações através de sucessivos treinamentos. Modelos de redes neurais podem aprender com exemplos, incorporar muitas variáveis, e fornecer respostas adequadas e rápidas para novas informações não apresentadas previamente. As características que fazem com que as redes neurais sejam atrativas para inúmeras aplicações são a sua capacidade de aprender e generalizar relações numa série de dados complexos (SABLANI et al., 1997).

Aplicações de redes neurais artificiais em engenharia de alimentos têm crescido consideravelmente e se tornado uma importante ferramenta com propósito de predição, controle de qualidade e de reconhecimento de modelos (SREEKANTH et al, 1998). Dentre estas, incluem: predição do desempenho da secagem de arroz (RAMESH et al.,

1996), predição do tempo de vida de prateleira do leite (VALLEJO et al., 1995), modelagem de um secador de leite fluidizado para prever a temperatura do ar de saída, umidade, temperatura de saída da partícula e umidade como função da temperatura de entrada do ar, taxa de escoamento e tempo de residência (BALASUBRAMANIAN et al., 1996), desenvolvimento de um protótipo baseado em redes neurais para um sistema de controle supervisionado para a fermentação do *Bacillus thuringiensis* (ZHANG et al., 1994), predição da qualidade de cozimento do pão baseado em testes de qualidade da farinha de trigo (HORIMOTO et al., 1995), modelagem de processos de secagem (JINESCU & LAVRIC, 1995), controle e predição de parâmetros de qualidade na fermentação da cerveja (GARCIA et al., 1995), modelagem e simulação de extração líquido líquido (ALDRICH & SLATER, 1995; SARAIVA et al., 1998).

SABLANI et al. (1995) utilizaram redes neurais na otimização de processamento térmico, onde um algoritmo computacional, baseado no modelo fenomenológico foi desenvolvido para prever o efeito da temperatura em alimentos sob variadas condições de processamento térmico. A letalidade foi obtida para uma ampla faixa de variáveis de entrada (tamanho da lata, difusividade térmica do alimento e parâmetros cinéticos de fatores de qualidade) para temperaturas de esterilização entre 110 e 134°C (com intervalos de 2°C). Estes dados foram usados para treinamento de uma rede do tipo *backpropagation*. A predição de temperaturas ótimas de esterilização foram obtidas com acuracidade de  $\pm 0,5^\circ\text{C}$ .

SABLANI et al. (1997) utilizaram o modelo de redes neurais artificiais para determinação do coeficiente global de transferência de calor (U) e do coeficiente de transferência de calor do fluido para a partícula ( $h_{fp}$ ) associados a sistemas líquidos particulados, em latas sujeitas a rotação. Tanto U quanto  $h_{fp}$  são necessários para a modelagem dos perfis de tempo-temperatura no líquido e na partícula. Dados experimentais obtidos para U e  $h_{fp}$  em várias condições foram usados tanto para o treinamento quanto generalização. Redes neurais de multicamadas foram treinadas com sete nodos de entrada e dois nodos de saída (para uma partícula na lata), e 6 nodos de entrada e dois nodos de saída (para múltiplas partículas na lata). A rede ótima foi obtida variando o número de camadas intermediárias e o número de nodos em cada camada intermediária, usando um algoritmo *back-propagation*. Os coeficientes de transferência de calor foram preditos usando correlações adimensionais desenvolvidas pela mesma série de dados. Os erros de predição com redes neurais foram menores que 3 e 5 %,

respectivamente, para  $U$  e  $h_{fp}$ , os resultados utilizando redes neurais foram 50% melhores comparados com os demais modelos usando correlações adimensionais.

AFAGHI et al. (2001) avaliaram modelos de redes neurais artificiais como alternativas para os métodos de cálculos para o processamento térmico convencional. Simulações com modelos fenomenológicos foram utilizadas para gerar perfis de temperatura em condições de operação do processamento térmico e uma ampla faixa de tamanhos de latas. Dados de tempo-temperatura foram utilizados para avaliar os parâmetros de penetração de calor,  $f_h$ ,  $j_{ch}$ ,  $f_c$  e  $j_{cc}$  como também computar a letalidade e o tempo de processo. Esses dados foram utilizados para desenvolver uma rede neural. Os métodos de Ball, Stumbo e Pham também foram utilizados para calcular os tempos de processo e as letalidades. A precisão e habilidade dos modelos de redes neurais foram comparadas com os métodos matemáticos, utilizando dados do modelo matemático como referência. Os resultados dos cálculos de processo do modelo de redes neurais foram equivalentes, e algumas vezes melhores e mais flexíveis que os métodos de Stumbo e Pham.

Este trabalho propõe uma nova técnica para avaliação *on line* da letalidade do processamento térmico de alimentos enlatados. Um modelo do processo baseado na técnica de redes neurais foi desenvolvido, de forma que a temperatura do ponto frio é predita a partir das condições iniciais do produto e da temperatura da autoclave, ao longo do tempo, permitindo o cálculo da letalidade a todo instante. Paralelamente, uma segunda rede neural foi usada para determinar o valor da letalidade durante a etapa de resfriamento. Desta forma, a letalidade total do processo, estaria sendo calculada instantaneamente independente das perturbações que pudessem ocorrer no processo.

## **2. MATERIAIS E MÉTODOS**

O produto utilizado para o processamento térmico foi uma pasta de fígado, composta por 20 % de fígado suíno, 60% de carne suína e 20% de água, preparada em um *cutter* (Mainca, Inglaterra).

Latas cilíndricas de 340 g contendo a pasta de fígado foram processadas em uma autoclave vertical descontínua, utilizando vapor como meio de aquecimento. As latas foram preparadas, instalando-se termopares tipo T no seu centro, a fim de que a temperatura no ponto frio fosse monitorada durante o processo. Logo após o envase e

fechamento, as latas foram mantidas em banho térmico para ajuste e homogeneização da sua temperatura inicial. Em seguida, foram acondicionadas lado a lado dentro da autoclave que, após fechada, foi iniciado o processo. Um controlador proporcional-integral (Spirax Sarco, Inglaterra) foi utilizado para controlar a temperatura do processo. Para a tomada de tempo e temperatura foi utilizado um equipamento com sistema de aquisição de dados *Field Logger* (Novus, Brasil), acoplado aos termopares tipo T. Ao término da esterilização, seguiu-se a etapa de resfriamento, com pressurização com ar para evitar estufamento das latas até temperatura inferior a 100°C. O resfriamento prosseguiu até que a temperatura no ponto frio atingisse 40°C.

A fim de obter um conjunto de dados experimentais em função das variáveis operacionais tempo e temperatura, vários processos foram conduzidos utilizando quatro temperaturas para a autoclave: (113, 117, 121 e 125)°C. Para cada temperatura da autoclave foram testadas três temperaturas iniciais do produto: (25, 35 e 45)°C. Perturbações foram aplicadas na temperatura da autoclave durante o processamento, simulando falhas ocorridas no processo real a (10, 30 e 50) minutos do início do processamento. Todas as perturbações tiveram duração de três minutos e foram realizadas interrompendo a entrada de vapor. O sistema de aquisição de dados registrou o tempo e a temperatura no centro do produto a cada 20 segundos.

O produto foi caracterizado quanto ao: a) teor de gordura, segundo o método de intermitente Soxhlet; b) umidade, segundo o método gravimétrico, c) proteína, segundo o método Kjeldahl (PRICE e SCHWEIGERT, 1994).

## **2.1 Modelagem utilizando redes neurais artificiais**

O processamento térmico do produto cárnico foi realizado a fim de obter um conjunto de dados experimentais em função das variáveis tempo e temperatura para o desenvolvimento e treinamento de uma rede neural.

Para a modelagem do processamento térmico foi usada uma rede recorrente, do tipo *back-propagation through time* (BPTT). As variáveis de entrada foram: o tempo de processo, a temperatura da autoclave e a temperatura do ponto frio para o tempo presente  $t_i$  e tempos anteriores  $t_{i-1}$ ,  $t_{i-2}$ . O parâmetro de saída foi representado pela

temperatura no ponto frio no tempo  $t_{i+1}$ . Portanto, a rede construída foi composta de cinco nodos na camada de entrada e um nodo na camada de saída.

Para o desenvolvimento do modelo desta rede foi empregado um software comercial, NeuralWorks Professional II/ Plus (*Neuralware Inc.*, Pittsburg, PA, USA). Para determinar a topologia ótima da rede, tanto a escolha da regra de aprendizagem, quanto o número de camadas intermediárias com seu respectivo número de neurônios, como para os coeficientes de aprendizagem utilizou-se o método de tentativa e erro que resultasse no menor erro de validação.

Na etapa de treinamento, foi usado um conjunto de 25112 dados obtidos no processamento térmico do produto Simultaneamente ao treinamento, foi realizada a etapa de teste da rede utilizando um conjunto contendo 8968 dados. Esta etapa é importante, uma vez que a sobreparametrização da rede pode ser evitada.

Na etapa de generalização, um conjunto contendo 4298 dados de tempo-temperatura, foi usado para testar o desempenho da mesma.

A letalidade dos microorganismos representa o efeito letal de um tratamento térmico a qualquer temperatura. Para o cálculo da letalidade ( $L$ ) foram usados como temperatura de referência,  $T_{ref}=121.1$  °C e um valor de “ $z$ ” igual a 10 °C. A expressão para o cálculo da letalidade é dada por (MAFART, 1994):

$$L = 10^{\frac{(T-121.1)}{10}} \quad (1)$$

O valor de  $F$  foi calculado pela seguinte integração de  $L$  ao longo do tempo, segundo a equação (2):

$$F = \int_{t_o}^{t_f} L dt \quad (2)$$

onde:

$t_f$  é o tempo em minutos no final do processo e  $t_o$  é o tempo em minutos no início do processo

O valor da letalidade na etapa de resfriamento foi previsto por uma rede *back-propagation*. A rede possuía como parâmetros de entrada a temperatura no centro do produto no início do resfriamento, a temperatura no centro do produto no final do resfriamento e a temperatura da água de resfriamento. O parâmetro de saída foi representado pelo valor de  $F$  no resfriamento calculado segundo a equação (2). Portanto,



a rede construída foi composta de três nodos na camada de entrada e um nodo na camada de saída.

Para o desenvolvimento do modelo desta rede foi utilizado um software comercial, NeuralWorks Professional II/ Plus (*Neuralware Inc.*, Pittsburg, PA). Para o treinamento e aprendizagem da rede neural foi usado o algoritmo *back-propagation*. Para determinar a topologia ótima da rede, a escolha da regra de aprendizagem, do número de camadas intermediárias com seu respectivo número de neurônios, como para os coeficientes de aprendizagem foi utilizado o método de tentativa e erro.

O treinamento foi realizado com um conjunto de 68 dados obtidos no processamento térmico do produto. A etapa de teste da rede foi realizada utilizando um conjunto contendo 20 dados. E a generalização foi feita a partir de um conjunto contendo 11 dados de tempo-temperatura.

### **3. RESULTADOS E DISCUSSÃO**

O processamento térmico do produto cárnico composto por 8,03 % de gordura, 12,3 % de proteína e 72 % de água teve como objetivo gerar dados necessários para o desenvolvimento de uma estrutura de rede neural.

Para o treinamento e aprendizagem da rede neural para o processo completo utilizou-se o algoritmo *back-propagation through time*. A regra de aprendizagem que ofereceu menor erro de validação, bem como maior coeficiente de correlação foi a regra delta. A função de ativação usada foi a sigmoideal. A partir dos dados de validação, o erro associado calculado foi o erro quadrado médio. A topologia da rede que apresentou o menor erro quadrático médio é apresentada da Figura 4.1, e foi composta por duas camadas intermediárias com 8 nodos na primeira camada e 9 nodos na segunda.




Figura 4.1 – Topologia da rede *back-propagation through time*

Na etapa de resfriamento o treinamento da rede foi feito com o auxílio do algoritmo *back-propagation*. A regra de aprendizagem que ofereceu menor erro de validação, bem como maior coeficiente de correlação foi a regra delta-bar-delta estendida. A função de ativação usada foi a tangente hiperbólica. A topologia da rede que apresentou o menor erro quadrado médio é apresentada da Figura 4.2, e foi composta por duas camadas intermediárias com 14 nodos na primeira camada e 10 nodos na segunda.




Figura 4.2– Topologia da rede *back-propagation*

As Figuras 4.3 e 4.4 a análise entre as previsões feitas pela rede *back-propagation* e os valores experimentais da temperatura no ponto frio, ao longo do tempo para o processo completo e para a etapa de resfriamento e os dados de validação. Observa-se uma boa concordância entre os valores experimentais e preditos ao longo de todo o processo, demonstrando sua habilidade em prever a temperatura no ponto frio nas etapas de aquecimento e resfriamento, bem como na fase de transição entre essas etapas. Na etapa de resfriamento as previsões foram razoáveis, motivadas pela dificuldade no controle da pressa da autoclave, no início do resfriamento, para evitar estufamento das latas.

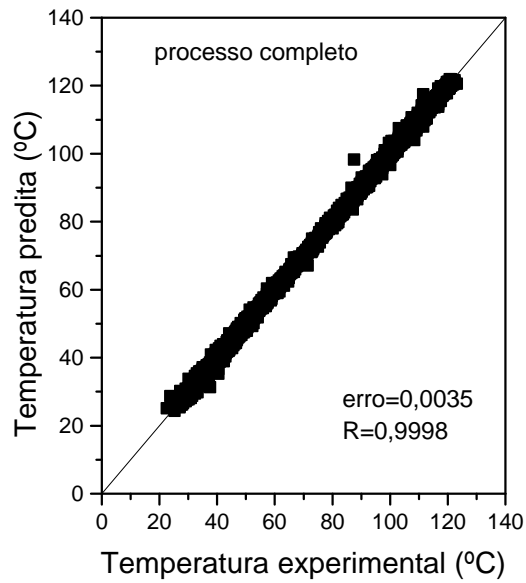


Figura 4.3 – Temperatura predita versus temperatura experimental ao longo do processo

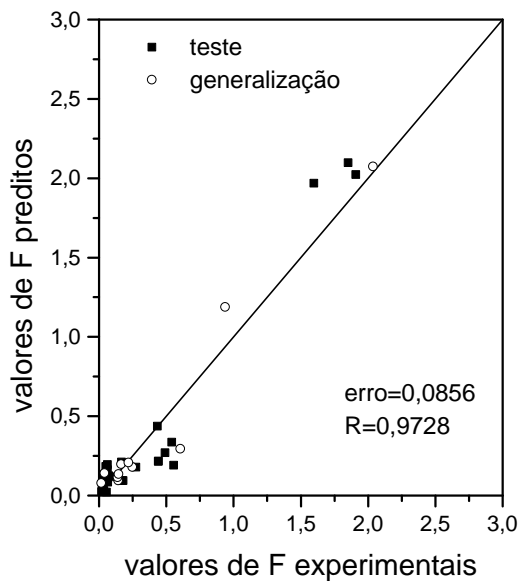


Figura 4.4 – Valores de F preditos e experimentais, na etapa de resfriamento

A Figura 4.5 apresenta o perfil de temperatura no ponto frio ao longo do tempo, para os processos A, B, C e D visto na Tabela 4.1. Observa-se uma boa concordância entre os valores experimentais e os preditos pelas redes neurais. Este fato também foi observado para o valor da letalidade acumulada do processo ao longo do tempo apresentado na Figura 4.6.

Tabela 4.1 – Parâmetros operacionais utilizados na etapa da generalização

experimento	Condições operacionais		
	Temperatura da autoclave (°C)	Temperatura inicial do produto (°C)	Perturbação (min)
A	113	25	10
B	117	45	50
C	121	45	50
D	125	35	30

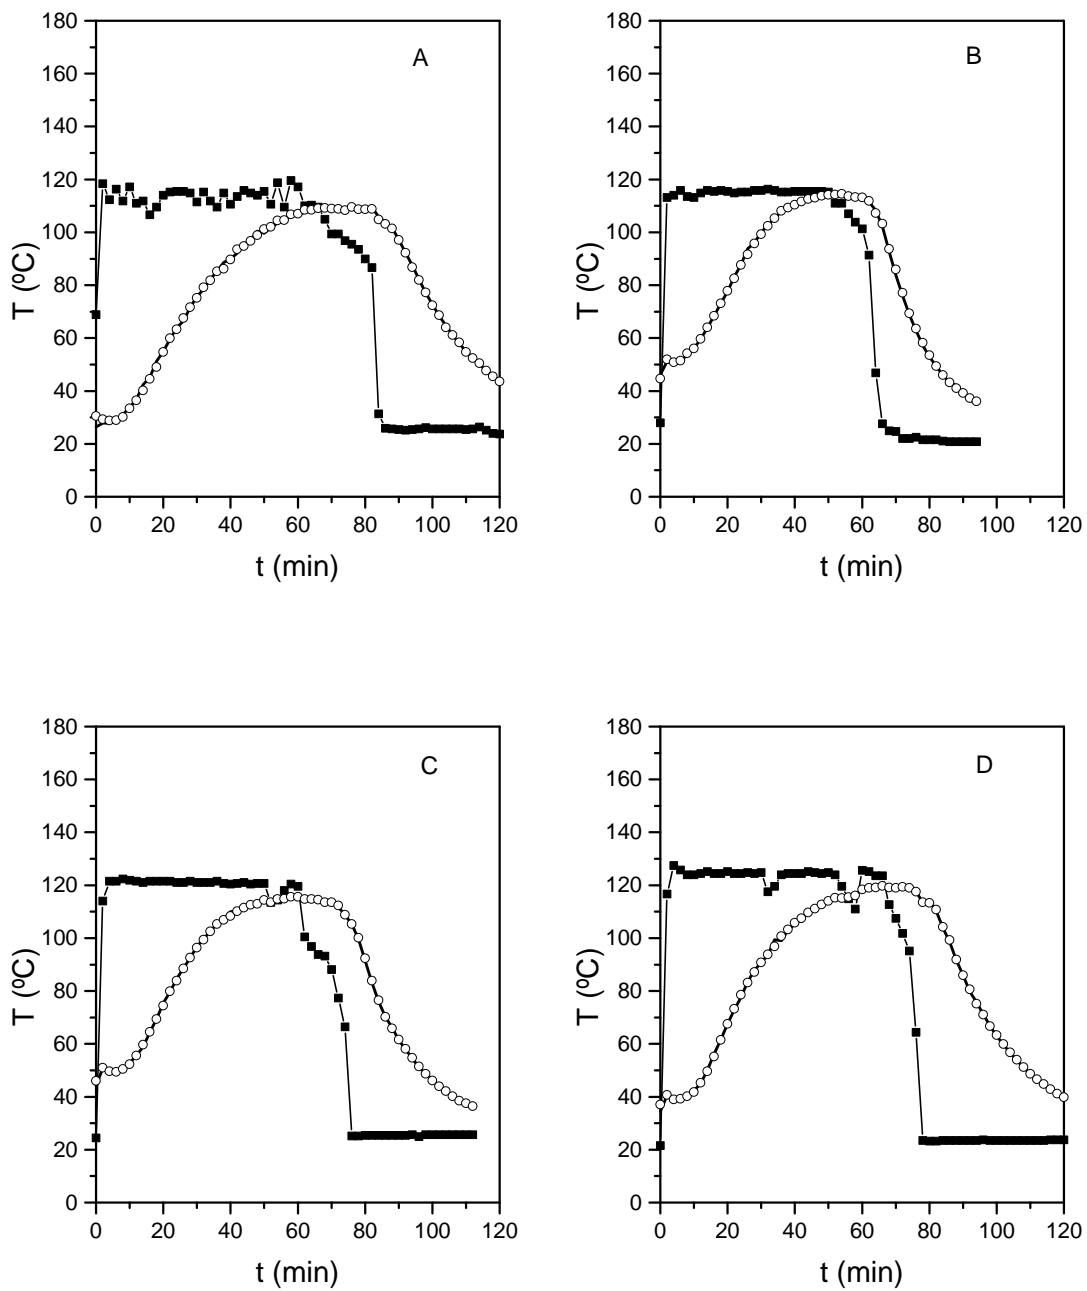


Figura 4.5 – Perfis de temperatura da autoclave e ponto frio ao longo do tempo;

comparação entre dados experimentais e preditos

—■— autoclave    — experimento    ○ predito

A Tabela 4.2 apresenta os valores de F calculados com os dados de tempo-temperatura experimentais e preditos pelas redes. A rede *backpropagation* apresentou desvios não superiores a 0,0264 do valor de F determinado experimentalmente, o que a torna apropriada para uso como modelo preditivo do processamento térmico de alimentos.

Tabela 4.2 – Comparação entre valores de F experimentais e preditos

experimento	Valores de F		Diferença
	Experimental	Predito	
A	1,722	1,762	0,0232
B	4,318	4,411	0,0215
C	6,591	6,702	0,0168
D	16,095	15,67	0,0264

A rede desenvolvida para a etapa de resfriamento obtida a partir dos processos apresentados na Tabela 4.3 apresentou boa concordância entre os valores da letalidade do processo (F) experimentais (Tabela 4.4). Nota-se que a rede *backpropagation* apresentou desvios não superiores a 0,31 min em relação ao valor de F determinado experimentalmente, representando um erro absoluto médio de 0,706.

Tabela 4.3 – Parâmetros operacionais utilizados na etapa da generalização

experimento	Condições operacionais		
	Temperatura da autoclave (°C)	Temperatura inicial do produto (°C)	Perturbação (min)
1	113	25	10
2	113	35	30
3	113	45	50
4	117	25	10
5	117	35	30
6	117	45	50
7	121	45	10
8	121	45	30
9	121	45	50
10	125	25	10
11	125	35	30

Tabela 4.4 – Comparação entre valores de F experimentais e preditos

Experimentos	Valores de F		
	Experimentais (min)	Preditos (min)	Diferença (min)
1	0,1435	0,0956	0,05
2	0,1640	0,1974	0,03
3	0,0177	0,0779	0,06
4	0,1391	0,1149	0,02
5	0,2474	0,1792	0,07
6	0,2197	0,2078	0,01
7	0,1460	0,1356	0,01
8	0,6038	0,2947	0,31
9	0,0410	0,1418	0,10
10	2,0369	2,0739	0,04
11	0,9379	1,1886	0,25

Na Tabela 4.5 observar-se os valores de F correspondentes às etapas de aquecimento e resfriamento e o seu valor total, para diferentes tempos do processo. Os valores de F referentes ao aquecimento foram obtidos da curva de penetração de calor em pontos estratégicos para cada processamento analisado. Entretanto, os valores de F referentes ao resfriamento foram obtidos através da rede desenvolvida para esta etapa. Estes valores foram analisados apenas para temperaturas no centro do produto acima de



100°C visto que a rede para a etapa de resfriamento foi desenvolvida para esta faixa de temperatura.

Observando o processo A, vimos que a temperatura no centro do produto após 68,7 minutos foi de 110°C. Se neste instante fosse iniciado o resfriamento, o valor de F total do processo, considerando as contribuições relativas ao aquecimento e resfriamento, não atingiria o valor pré-estabelecido igual a 3 minutos (cocção botulínica), indicando que o processo realizado foi insuficiente. Já no processo C, com 55,3 min de processamento, a temperatura no centro do produto era 115°C e a soma das contribuições letais referentes ao aquecimento e resfriamento foi de 3,0 min, demonstrando que o aquecimento poderia ser interrompido neste ponto e iniciado imediatamente o resfriamento. No processo D pode-se observar que o aquecimento poderia ser interrompido a 54,3 minutos do início do processamento, quando a temperatura no centro do produto era 115°C, apresentando um valor de F de 3,18 minutos.

Deve ser ressaltado que neste método o valor da letalidade do processo era obtido a todo instante, independente das condições do processo, bastando apenas o conhecimento de sua temperatura instantânea. Sendo assim, nenhuma correção do processo seria necessária no seu final.

Tabela 4.5 - Comparação entre valores de F preditos

experimento	tempo (min)	Temperatura no centro do produto (°C)	F aquecimento (min)	F resfriamento (min)	F total (min)
A	48,33	100	0,03	0,07	0,10
	57,33	105	0,16	0,10	0,26
	68,67	110	0,72	0,25	0,97
C	32,67	100	0,02	0,03	0,05
	36,33	105	0,08	0,08	0,16
	40,33	110	0,26	0,24	0,50
	55,33	115	2,51	0,55	3,06
D	36,00	100	0,02	0,06	0,09
	40,00	105	0,09	0,08	0,17
	44,67	110	0,31	0,21	0,52
	54,33	115	2,08	1,09	3,18

#### 4. CONCLUSÃO

Redes neurais apresentaram grande capacidade para a modelagem do processamento térmico de alimentos quando analisado o processo completo e a etapa de resfriamento em separado predizendo acertadamente as novas temperaturas do produto e os novos valores de F, respectivamente. Ficou demonstrada a viabilidade deste método, onde o cálculo do processo poderá ser realizado de forma *on line*, e deste modo o algoritmo seria responsável pela interrupção do aquecimento e início imediato do resfriamento a qualquer momento em que a soma das contribuições da letalidade no aquecimento e no resfriamento atingirem um valor de F necessário para garantir a qualidade final do produto.

Neste método, não há correção de falhas uma vez que não se pré-determina as condições do processo.

A principal vantagem deste modelo está na capacidade de predição da letalidade no final do processo, para condições não apresentadas previamente, e independente das variações ocorridas.

## 5. REFERÊNCIAS BIBLIOGRÁFICAS

- AFAGHI, M., RAMASWAMY, H. S., PRASHER, S. O. Thermal process calculations using artificial neural network models. **Food Research International**, v. 34, p. 55-65, 2001.
- ALDRICH, C., SLATER, M. J. Neural separation – how neural networks will lead to better control and simulation of extraction columns. **The Chemical Engineer**, v. 15, p. 11-18, 1995.
- BALASUBRAMANIAM, A., PANDA, R. C., RAMACHANDRA, R.V.S. Modelling of a fluidized-bed dryer using artificial neural network. **Drying Technology**, v. 14, n. 7, p. 1881-1889, 1996.
- GARCIA, L., ARGUESO, F., GARCIA, A., DIAZ, M. Application of neural networks for controlling and predicting quality parameters in beer fermentation. **Journal of Industrial Microbiology**, v. 15, p. 401-406, 1995.
- HORIMOTO, Y., DURANCE, T., NAKAI, S. Neural network vs principal component regression for prediction of wheat flour foaf volume in baking tests. **Journal of Food Science**, v. 60, n. 3, p. 429-433, 1995.
- JINESCU, G., LAVRIC, V. The artificial neural networks and the drying process modeling. **Drying Technology**, v. 13, n. 5-7, p. 1579-1586, 1995.
- MAFART, P., **Procesos físicos de conservacion. Editorial Acribia Saragoza España**, v.1, 1994. 285p.
- PRICE, J. F., SCHWEIGERT, B. S. **Ciência de la carne y de los productos cárnicos**. Acribia, S. A., 1994. 581 p.
- RAMESH, M. N., KUMAR, M. A., SRINIVASA RAO, P. N. Application of artificial neural networks to investigate the drying of cooked rice. **Journal of Food Process Engineering**, v. 19, p. 321-329, 1996.
- SABLANI, S. S., RAMASWAMY, H.S., PRASHER, S. O. A neural network approach for thermal processing applications. **Journal of Food Process and Preservation**, v.19, p. 283-301, 1995.

- SABLANI, S. S., RAMASWAMY, H.S., SREEKANTH, S, PRASHER, S. O. Neural network modeling of heat transfer to liquid particle mixtures in cans subjected to end-over-end processing. **Food Research International**, v.30, n. 2, p. 283-301, 1997.
- SARAIVA, S. H., MINIM, L. A., COIMBRA, J. S. R., ALVARENGA, A.L. B. Artificial neural networks for efficiency prediction of perforated rotating disk contactor.. **V Simpósio Brasileiro de redes neurais. Ed. Antônio de Pádua Braga**, p. 169-179, 1998.
- SREEKANTH, S. RAMASWAMY, H. S., SABLANI, S. Prediction of psychrometric parameters using neural networks. **Drying Technology**, v. 16, n. 3-5, p. 825-837, 1998.
- TEIXEIRA, A. A., BALABAN, M. **Computer Application in Thermal Processing of Canned Foods**. Instituto de Tecnologia de Alimentos, Campinas – SP, 1996.
- TEIXEIRA, A. A., TUCKER, G. S. On-line retort control in thermal sterilization of canned foods. **Food Control**, v. 8, n.1, p. 13-20, 1997.
- VALLEJO-CORDOBA, B., ARTEAGA, G. E., NAKAI, S. Predicting milk shelf-life based on artificial neural networks and headspace gas chromatographic data. **Journal of Food Science**, v. 60, n. 5, p. 885-888, 1995.
- ZHANG, Q., REID, J. F., LITCHFIELD, J. B., REN, J., CHANG, S. A prototype neural network supervised control system for *bacillus thuringiensis* fermentations. **Biotechnology and Bioengineering**, v. 43, p. 483-489, 1994.

## **CONCLUSÕES GERAIS**

## 1. CONCLUSÕES

Redes neurais demonstraram grande capacidade para a modelagem do processamento térmico de alimentos, com vantagens como precisão e simplicidade já que não requerem informações exatas das propriedades termofísicas do produto e podem fornecer respostas adequadas e rápidas para novas informações não apresentadas previamente.

A rede *back-propagation through time* foi que apresentou melhores resultados no processamento completo do produto enlatado diante da rede Jordan. A topologia de rede 5-8-9-1 foi a que melhor se adequou ao problema em estudo apresentando excelente capacidade de generalização, para qualquer nova condição de processo, bem como situações de perturbações na temperatura da autoclave, com um erro relativo médio de 0,022.

O modelo de rede neural apresentou melhor desempenho na predição do valor de F quando comparados aos métodos matemáticos de Ball e de Stumbo. Os modelos de redes neurais demonstraram grande potencial como alternativa para os métodos matemáticos para o processamento térmico convencional com vantagens como precisão e simplicidade.

Na etapa de resfriamento, a rede *back-propagation* com topologia 5-14-10-1, foi a que apresentou menor erro ao predizer os valores de F quando novas condições de temperatura da autoclave e do produto foram fornecidas, com um erro relativo médio de 0,706.

Modelos de redes neurais demonstraram habilidade na predição do processamento térmico de alimentos, quando analisado o processo completo e a etapa de resfriamento em separado. Fato demonstrado ao predizer acertadamente as novas temperaturas do produto e os novos valores de F, respectivamente. Sendo então demonstrada a viabilidade do desenvolvimento de um algoritmo matemático, onde o cálculo do processo poderá ser realizado de forma *on line*, e deste modo o algoritmo seria responsável pela interrupção do aquecimento e início imediato do resfriamento a qualquer momento em que a soma das contribuições da letalidade no aquecimento e no resfriamento atingirem um valor de F necessário para garantir a qualidade final do produto.

O modelo desenvolvido, baseado na técnica de redes neurais, foi capaz de avaliar *on line* a letalidade no processamento térmico de alimentos enlatados. Desta

forma, a letalidade foi obtida corretamente no final do processo, independente das perturbações ocorridas durante o mesmo.

## 2. SUGESTÕES

Como sugestões para futuros trabalhos, propomos:

- Desenvolver um modelo do processamento térmico baseado na técnica de redes neurais utilizando como dados de entrada propriedades físicas e químicas de vários produtos a fim de analisar se essas propriedades são determinantes na predição do perfil de temperatura.
- Desenvolver um modelo híbrido do processamento térmico, utilizando a técnica de redes neurais em conjunto com programação genética para predição do perfil de temperatura do produto.
- Desenvolver um software baseado na técnica de redes neurais que acoplado a um sistema de controle de processos seja capaz de avaliar *on line* a letalidade no processamento térmico de alimentos enlatados.