

**UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ - UNIOESTE**  
**CENTRO DE ENGENHARIAS E CIÊNCIAS EXATAS**  
**PROGRAMA DE PÓS-GRADUAÇÃO “STRICTO SENSU” EM**  
**ENGENHARIA QUÍMICA – NÍVEL DE MESTRADO**

**USO DE REDES NEURAS ARTIFICIAIS PARA A MODELAGEM DA**  
**TEMPERATURA E DA RETENÇÃO DE ÁGUA NO PROCESSO DE**  
**RESFRIAMENTO DE CARÇAÇAS DE FRANGOS POR IMERSÃO**

**TÚLIO KLASSEN**

**TOLEDO - PR**

**2008**

**TÚLIO KLASSEN**

**USO DE REDES NEURAS ARTIFICIAIS PARA A MODELAGEM DA  
TEMPERATURA E DA RETENÇÃO DE ÁGUA NO PROCESSO DE  
RESFRIAMENTO DE CARCAÇAS DE FRANGOS POR IMERSÃO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Química em cumprimento parcial aos requisitos para obtenção do título de Mestre em Engenharia Química, área de concentração em **Desenvolvimento de Processos**.

Orientador: Prof. Dr. Edson Antônio da Silva

Co-orientador: Prof. Dr. Lúcio Cardozo Filho

**TOLEDO - PR**

**2008**

Catálogo na Publicação elaborada pela Biblioteca Universitária  
UNIOESTE/Campus de Toledo.  
Bibliotecária: Marilene de Fátima Donadel - CRB – 9/924

K63u	<p>Klassen, Túlio</p> <p>Uso de redes neurais artificiais para a modelagem da temperatura e da retenção de água no processo de resfriamento de carcaças de frangos por imersão / Túlio Klassen.. -- Toledo, PR : [s. n.], 2008. 59 f. Orientador: Dr. Edson Antônio da Silva Co-orientador: Dr. Lúcio Cardozo Filho Dissertação (Mestre em Engenharia Química) - Universidade Estadual do Oeste do Paraná. Campus de Toledo. Centro de Engenharias e Ciências Exatas.</p> <p>1. Redes neurais (Computação) 2. Inteligência artificial - Aplicações industriais 3. Frango de corte- Carcaça - Resfriamento - Modelagem 4. Resfriamento 6. Processos industriais - Modelagem 7. Tecnologia de alimentos 8. Chillers I. Silva, Edson Antônio da, Or. II. Cardozo Filho, Lúcio, Or. III.T</p> <p>CDD 20. ed. 660.2815 664. 9353</p>
------	---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

## SUMÁRIO

<b>RESUMO</b> .....	<b>vii</b>
<b>ABSTRACT</b> .....	<b>viii</b>
<b>1. Introdução</b> .....	<b>1</b>
<b>2. Revisão Bibliográfica</b> .....	<b>3</b>
<b>2.1 Processo de abate de frangos</b> .....	<b>3</b>
<b>2.2 Resfriamento por imersão</b> .....	<b>5</b>
<b>2.3 Modelagem convencional</b> .....	<b>13</b>
<b>2.3.1 Modelagem do resfriamento</b> .....	<b>13</b>
<b>2.3.2 Modelagem da absorção de água</b> .....	<b>15</b>
<b>2.4 Modelagem por redes neurais e uso na indústria</b> .....	<b>15</b>
<b>2.4.1 Redes Neurais Artificiais e o Neurônio Biológico</b> .....	<b>16</b>
<b>2.4.2 Redes Neurais Artificiais como Ferramenta Computacional</b> .....	<b>18</b>
<b>2.5 Modelos utilizados para treinar a rede</b> .....	<b>22</b>
<b>2.5.1 Treinamento não-supervisionado</b> .....	<b>22</b>
<b>2.5.2 Treinamento supervisionado</b> .....	<b>23</b>
<b>2.6 Métodos de otimização</b> .....	<b>23</b>
<b>2.6.1 Método Simplex</b> .....	<b>24</b>
<b>2.6.2 Método de Powell</b> .....	<b>24</b>
<b>2.6.3 Simulated Annealing</b> .....	<b>25</b>
<b>3. Modelagem Matemática</b> .....	<b>26</b>
<b>3.1 Esquema do processo a ser modelado</b> .....	<b>26</b>
<b>3.2 Variáveis de entrada e saída</b> .....	<b>26</b>
<b>3.3 Coleta de dados</b> .....	<b>28</b>
<b>3.4 Arquitetura da rede</b> .....	<b>30</b>
<b>3.5 Treinamento da rede</b> .....	<b>30</b>
<b>3.6 Efeitos das variáveis do processo</b> .....	<b>31</b>
<b>3.7 Modelagem fenomenológica</b> .....	<b>31</b>
<b>3.8 Métodos de otimização</b> .....	<b>31</b>
<b>4. Resultados</b> .....	<b>32</b>
<b>4.1 Previsão somente da temperatura</b> .....	<b>32</b>
<b>4.2 Previsão somente da massa</b> .....	<b>34</b>
<b>4.3 Previsão conjunta da massa e da temperatura</b> .....	<b>36</b>

<b>4.4</b>	<b>Uso de redes com arquiteturas alternativas .....</b>	<b>39</b>
<b>4.5</b>	<b>Modelagem do processo de resfriamento separado de cada um dos chillers .....</b>	<b>42</b>
<b>4.6</b>	<b>Análise da influência das variáveis .....</b>	<b>44</b>
<b>4.7</b>	<b>Análise da rotinas de otimização .....</b>	<b>46</b>
<b>4.8</b>	<b>Aplicação do modelo fenomenológico para previsão da massa .....</b>	<b>48</b>
<b>4.9</b>	<b>Aplicação da Lei de Newton do Resfriamento para previsão da temperatura .....</b>	<b>49</b>
<b>4.10</b>	<b>Desenvolvimento de planilha para previsão da absorção .....</b>	<b>51</b>
<b>5.</b>	<b>Conclusão .....</b>	<b>53</b>
<b>6.</b>	<b>Bibliografia .....</b>	<b>55</b>

## ÍNDICE DE FIGURAS

Figura 01 – Foto de uma nórea de pendura de frangos vivos .....	4
Figura 02 – Foto de um Air Chiller .....	5
Figura 03 – Desenho em corte transversal de um chiller .....	6
Figura 04 – Chiller de resfriamento com água .....	6
Figura 05 – Chiller com gelo sobrenadante .....	7
Figura 06 – Esquema de funcionamento das camisas de propilenoglicol.....	8
Figura 07 – Chiller com agitação por borbulhamento de ar .....	8
Figura 08 – Mudanças que ocorrem nos músculos das aves <i>post mortem</i> .....	12
Figura 09 – Estrutura básica de um neurônio e suas partes .....	17
Figura 10 - Constituintes do neurônio artificial .....	18
Figura 11 – Arquitetura em camadas de uma rede neural.....	20
Figura 12 – Extremos de uma função em um intervalo .....	24
Figura 13 – Fluxo do processo em estudo.....	27
Figura 14 – Erro no treinamento e validação da rede, prevendo apenas temperatura, para diferentes arquiteturas .....	33
Figura 15 – Correlação no treinamento e validação da rede, prevendo apenas temperatura, para diferentes arquiteturas .....	33
Figura 16 – Número de iterações no treinamento da rede, prevendo apenas temperatura, para diferentes arquiteturas .....	34
Figura 17 – Correlação entre o número de pesos da rede e o número de iterações até convergência.....	34
Figura 18 – Erro no treinamento e validação da rede, prevendo apenas a massa final, para diferentes arquiteturas .....	35
Figura 19 – Correlação no treinamento e validação da rede, prevendo apenas a massa final, para diferentes arquiteturas .....	35
Figura 20 – Número de iterações no treinamento, prevendo apenas a massa final, para diferentes arquiteturas .....	36
Figura 21 – Correlação entre o número de pesos da rede e o número de iterações até convergência.....	36
Figura 22 – Erro no treinamento e validação da rede, prevendo temperatura a massa ao mesmo tempo, para diferentes arquiteturas .....	37

<b>Figura 23 – Correlação no treinamento e validação da rede, prevendo temperatura e massa ao mesmo tempo, para diferentes arquiteturas.....</b>	<b>37</b>
<b>Figura 24 – Número de iterações no treinamento da rede, prevendo temperatura e massa ao mesmo tempo, para diferentes arquiteturas.....</b>	<b>38</b>
<b>Figura 25 – Correlação entre o número de pesos da rede e o número de iterações até convergência.....</b>	<b>38</b>
<b>Figura 26 – Erro no treinamento e validação da rede, prevendo temperatura e massa ao mesmo tempo, para arquiteturas alternativas.....</b>	<b>39</b>
<b>Figura 27 – Correlação no treinamento e validação da rede, prevendo temperatura e massa ao mesmo tempo, para arquiteturas alternativas.....</b>	<b>39</b>
<b>Figura 28 – Número de iterações no treinamento da rede, prevendo temperatura e massa ao mesmo tempo, para arquiteturas alternativas.....</b>	<b>40</b>
<b>Figura 29 – Correlação entre o número de pesos da rede e o número de iterações até convergência.....</b>	<b>40</b>
<b>Figura 30 – Gráfico de correlação entre a temperatura real normalizada e a temperatura prevista normalizada no treinamento da rede 4 x 12 x 4 prevendo também a massa.....</b>	<b>41</b>
<b>Figura 31 – Gráfico de correlação entre a temperatura real normalizada e a temperatura prevista normalizada na validação da rede 4 x 12 x 4 prevendo também a massa.....</b>	<b>41</b>
<b>Figura 32 – Gráfico de correlação entre a massa real normalizada e a massa prevista normalizada no treinamento da rede 4 x 12 x 4 prevendo também a temperatura.....</b>	<b>42</b>
<b>Figura 33 – Gráfico de correlação entre a massa real normalizada e a massa prevista normalizada na validação da rede 4 x 12 x 4 prevendo também a temperatura.....</b>	<b>42</b>
<b>Figura 34 – Erro no treinamento e validação da rede, prevendo temperatura e massa ao mesmo tempo, no final de cada um dos chillers, para a arquitetura 4 x 12 x 4.....</b>	<b>43</b>
<b>Figura 35 – Correlação no treinamento e validação da rede, prevendo temperatura e massa ao mesmo tempo, no final de cada um dos chillers, para a arquitetura 4 x 12 x 4.....</b>	<b>43</b>
<b>Figura 36 – Influência de cada uma das variáveis na previsão da temperatura das carcaças para a rede 4 x 12 x 4 prevendo também a massa.....</b>	<b>45</b>
<b>Figura 37 – Influência de cada uma das variáveis na previsão da massa das carcaças para a rede 4 x 12 x 4 prevendo também a temperatura.....</b>	<b>45</b>
<b>Figura 38 – Erro no treinamento e validação da rede prevendo temperatura e massa ao mesmo tempo para a arquitetura 4 x 12 x 4 e para as diferentes rotinas de otimização.....</b>	<b>47</b>

<b>Figura 39 – Correlação no treinamento e validação da rede prevendo temperatura e massa ao mesmo tempo para a arquitetura 4 x 12 x 4 e para as diferentes rotinas de otimização.....</b>	<b>47</b>
<b>Figura 40 – Gráfico de correlação entre a massa real normalizada e a massa prevista normalizada na aplicação do modelo de CARCIOFI &amp; LAURINDO para o pré-chiller</b>	<b>48</b>
<b>Figura 41 – Gráfico de correlação entre a massa real normalizada e a massa prevista normalizada na aplicação do modelo de CARCIOFI &amp; LAURINDO para o chiller 1 ...</b>	<b>49</b>
<b>Figura 42 – Gráfico de correlação entre a massa real normalizada e a massa prevista normalizada na aplicação do modelo de CARCIOFI &amp; LAURINDO para o chiller 2 ...</b>	<b>49</b>
<b>Figura 43 – Gráfico de correlação entre a temperatura real normalizada e a temperatura prevista normalizada na aplicação da Lei do Resfriamento de Newton para o pré-chiller .....</b>	<b>50</b>
<b>Figura 44 – Gráfico de correlação entre a temperatura real normalizada e a temperatura prevista normalizada na aplicação da Lei do Resfriamento de Newton para o chiller 1 .....</b>	<b>50</b>
<b>Figura 45 – Gráfico de correlação entre a temperatura real normalizada e a temperatura prevista normalizada na aplicação da Lei do Resfriamento de Newton para o chiller 2 .....</b>	<b>51</b>
<b>Figura 46 – Tela de interface com o operador da planilha de cálculo para previsão da massa final das carcaças .....</b>	<b>52</b>



## RESUMO

As Redes Neurais Artificiais têm sido empregadas com sucesso para a descrição e modelagem de processos nas mais diversas áreas do conhecimento, desde economia, administração, inteligência artificial e até controle de processos industriais complexos. O processo de resfriamento de frangos por imersão em água gelada (“chillers”) é complexo e difícil de ser modelado fenomenologicamente, pois envolve transferência de calor, massa e regime transiente, além de um grande número de variáveis. Neste trabalho foram empregadas diversas arquiteturas de redes neurais artificiais na descrição e modelagem do processo de resfriamento dos frangos, prevendo a temperatura final e o ganho de peso das carcaças. Também para efeito de comparação foram empregados um modelo empírico proposto por CARCIOFI & LAURINDO (2007) para descrever a absorção da água pelas carcaças e o modelo de resfriamento segundo a Lei de Newton para a temperatura das carcaças. Foram testadas diferentes situações alterando-se os números de neurônios das camadas de entrada e intermediária, e o número de camadas. Foram utilizados dados fornecidos pela empresa SADIA – Toledo para treinamento e validação da rede. Para o modelo foram selecionadas vinte e cinco variáveis de entrada, como peso da carcaça, temperatura antes do resfriamento, temperatura da camisa de propilenoglicol, vazão de água em cada módulo dos tanques, tempo de resfriamento e temperatura da água de renovação, borbulhamento e quantidade de gelo. Os resultados obtidos pelas redes neurais e pela Lei de Newton não foram eficientes para representar a temperatura de saída da carcaça. As redes neurais e o modelo empírico de CARCIOFI & LAURINDO (2007) foram muito eficientes para estimar a quantidade de água absorvida pelas carcaças. Os resultados obtidos mostraram que a rede tipo 4 x 12 x 4 neurônios na camada de entrada, primeira intermediária e segunda intermediária respectivamente foi a que melhor representou o sistema investigado.

Palavras chaves: resfriamento, chillers, redes neurais.

## **ABSTRACT**

The Artificial Neural Networks have been used with success for the description and modeling of processes in the most several areas of the knowledge, from economy, administration, artificial intelligence and even control of complex industrial processes. The process of chilling of chickens for immersion in cold water ("chillers") is complex and difficult to be modeled phenomenologically, because it involves transfer of heat, mass and transient regime, besides a great number of variables. In this work several architectures of artificial neural networks were used in the description and modeling of the process of chilling of the chickens, foreseeing the final temperature and the growth of weight of the carcasses. Also for comparison effect they were used an empiric model proposed by CARCIOFI & LAURINDO (2007) to describe the absorption of the water for the carcasses and the chilling model according to Newton's Law for the temperature of the carcasses. Different situations were tested changing the numbers of neurons of the entrance and hidden layers, and the number of layers. The data used were supplied by the SADIA - Toledo company for training and validation of the net. For the model twenty-five entrance variables were selected, as weight of the carcass, temperature before the chillers, temperature of the propilenoglicol shirt, flow of water in each module of the tanks, time of chilling and temperature of the renewal water, bubble intensity and amount of ice. The results obtained by the neural network and for Newton's Law they were not efficient to represent the final temperature of the carcass. The neural networks and the empiric model of CARCIOFI & LAURINDO (2007) went very efficient to esteem the amount of water absorbed for the carcasses. The obtained results showed that the net type with 4 x 12 x 4 neurons in the entrance layer, first and second hidden layers respectively was the best to represent the investigated system.

Key words: poultry chilling, chillers, artificial neural networks.

## 1. INTRODUÇÃO

O processo de resfriamento de carcaças de frango é complexo em sua modelagem fenomenológica, devido ao grande número de fatores que interferem no processo. As previsões que se consegue obter são aproximadas e muitas vezes baseadas em ajustes por correlação de dados empíricos, e com muitas idealizações.

Existem dois fatores básicos a serem observados no processo de resfriamento por imersão, que são a temperatura final das carcaças e a absorção de água. A legislação estabelece valores máximos para os dois parâmetros. O não atendimento da temperatura é limitante para o destino que se deseja dar ao frango, e da absorção pode gerar perdas financeiras para os clientes, caso o valor esteja acima do máximo, ou para a empresa, caso esteja abaixo do máximo.

Para um abatedouro de médio porte, com uma linha de abate automatizada, trabalhando 16 horas/dia, uma diferença de 1% na absorção de água equivale a um volume aproximado de 50 ton/mês, ou cerca de R\$ 100.000,00. Isto pode sair do bolso do consumidor ou do caixa da empresa, se estiver acima ou abaixo do limite legal.

As redes neurais artificiais representam um novo paradigma metodológico no campo da Inteligência Artificial, ou seja, no desenvolvimento de sistemas computacionais capazes de imitar tarefas intelectuais complexas, tais como a resolução de problemas, o reconhecimento e classificação de padrões, os processos indutivos e dedutivos etc.

Ao contrário dos sistemas baseados em lógica e em processamento simbólico, as redes neurais artificiais se inspiram em um modelo biológico para a inteligência, isto é, na maneira como o cérebro é organizado em sua arquitetura elementar, e em como a mesma é capaz de executar tarefas computacionais.

Da mesma maneira que no cérebro, as redes neurais artificiais são organizadas na forma de um número de elementos individuais simples (os neurônios), que se interconectam uns aos outros, formando redes capazes de armazenar e transmitir informação provinda do exterior. Outra capacidade importante das redes neurais artificiais é a auto-organização ou plasticidade, ou seja, através de um processo de aprendizado é possível alterar-se os padrões de interconexão entre seus elementos. Por este motivo, as redes neurais artificiais são um tipo de sistema conexionista, no qual as propriedades computacionais são resultado dos padrões de interconexão da rede, como acontece também no sistema nervoso biológico.

A aplicação de redes neurais na modelagem do resfriamento é uma alternativa viável na busca de resultados confiáveis de previsibilidade do processo.

Redes Neurais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Uma grande Rede Neural Artificial pode ter centenas ou milhares de unidades de processamento, já o cérebro de um mamífero pode ter muitos bilhões de neurônios.

As redes neurais podem ser utilizadas na resolução de uma grande classe de problemas encontrados em várias áreas aplicadas: classificação e identificação de padrões, diagnóstico de sistemas e comportamentos, análise de sinais e de imagens, otimização e controle de processos. As Redes Neurais tem se mostrado de fácil implementação, robustas no tratamento de dados com ruído, eficientes, especialmente nos problemas em que não se tem formulação analítica ou não se têm um conhecimento explícito acessível ou os dados "estão contaminados" por ruído ou o próprio problema modifica-se com o tempo. O emprego de uma Rede Neural depende da habilidade em adaptá-la ao problema considerado, por meio de mudanças nos pesos sinápticos (aprendizagem), de modo a aumentar sua eficiência. O estudo das Redes Neurais é um dos ramos da Inteligência Artificial que mais se desenvolve, atraindo pessoas de diversas áreas do conhecimento.

O objetivo principal deste trabalho é aplicar redes neurais artificiais para modelar o processo de resfriamento de carcaças de frango, prevendo a temperatura e a absorção de água. Além disto, se busca o desenvolvimento de um programa na linguagem Fortran para treinamento e simulação do processo que possa ser estendido para outras aplicações, e que seja um software não rígido que permita alterações e evoluções.

No capítulo 2 deste trabalho é feita uma revisão da bibliografia existente sobre o abate de frangos, mais detalhadamente o sistema de resfriamento. Este capítulo também cita os trabalhos já publicados sobre o assunto, descreve a modelagem por redes neurais artificiais e seu uso na indústria, os principais métodos de treinamento e otimização envolvidos. A modelagem empregada no desenvolvimento deste trabalho é descrita no capítulo 3. É detalhado o esquema do processo a ser modelado, as variáveis de entrada e saída envolvidas, o treinamento e os métodos de otimização empregados, e como foi feita a coleta de dados. No capítulo 4 são apresentados e comentados os resultados obtidos no treinamento e na validação da rede, as simulações feitas na busca da melhor arquitetura, e os comportamentos das rotinas de otimização. No último capítulo são apresentadas as principais conclusões obtidas a partir dos resultados deste trabalho.

## **2. REVISÃO BIBLIOGRÁFICA**

No processamento moderno de carne o resfriamento dos produtos é indispensável. Serve para retardar o desenvolvimento microbiano e também para diminuir a degradação natural do músculo decorrente da atividade enzimática. A infinidade de produtos de carne disponíveis hoje no mercado, *in natura* e processados, o padrão de qualidade e os longos prazos de validade não existiriam sem os processos de resfriamento.

Os processos de resfriamento por imersão em água gelada, por spray e ar frios são os métodos mais comumente utilizados para carcaças de frango (JAMES *et al*, 2006). Há um pequeno número de estudos utilizando sistemas criogênicos, mas não é de conhecimento nenhuma planta industrial que utilize este sistema comercialmente (Lillard, citado por JAMES *et al*, 2006).

Ainda segundo JAMES (et al, 2006) a taxa de resfriamento influencia no sabor, textura e aparência da carne de frango. Um resfriamento muito rápido resulta em uma carne mais dura, enquanto um resfriamento demasiadamente lento produz músculos pálidos, flácidos e exudativos (PSE).

Entre os diferentes métodos de resfriamento rápido destacam-se os sistemas de resfriamento com ar forçado (*forced-air cooling*) e com água gelada (*hydrocooling*). No primeiro método, os produtos são condicionados no interior de um túnel de ar forçado, estando composto por ventiladores, associados ao sistema de refrigeração da câmara. O ar resfriado deve entrar em contato com a maior área da embalagem que contém os produtos, permitindo uma eficiente troca de calor com o meio refrigerado (TERUEL *et al*, 2003).

Já no segundo método, o calor dos produtos é removido usando-se como meio de resfriamento água a baixas temperaturas. O resfriamento com água pode ser feito introduzindo os produtos em tanques de imersão, ou, usando-se o método de aspersão, onde a água é aspergida de forma contínua na superfície dos produtos. O resfriamento nestes tipos de sistemas, é rápido e eficiente, podendo ser aplicado numa ampla faixa de produtos (TERUEL *et al*, 2003).

### **2.1 Processo de abate de frangos**

O processamento de carnes envolve várias etapas, sendo que uma das mais importantes é a do resfriamento. A seguir é apresentada uma descrição sintética do processamento de frango empregado na Indústria Sadia de Toledo - PR.

O processo de abate de frangos se inicia no recebimento das aves vivas oriundas do campo. Estas chegam acondicionadas em gaiolas plásticas, e são penduradas em ganchos de aço inoxidável numa nórea de transporte. Esta nórea consiste em um trilho feito em perfil “T” invertido, sobre o qual correm rodízios plásticos unidos por uma peça plástica em forma de “C”. Este conjunto é chamado de trolley. Um trolley é unido ao outro por uma corrente, e em cada um é preso um gancho, formando então a nórea, conforme mostrado na Figura 01.



Figura 01 – Foto de uma nórea de pendura de frangos vivos. Fonte: Catálogo Linco.

Depois de penduradas, as aves são insensibilizadas por eletronarcese, que é feita em um tanque de fibra contendo água. No fundo do tanque há um eletrodo, e outro toca o gancho. Ao passarem pelo tanque, com a cabeça imersa na água, as aves recebem uma descarga elétrica que provoca a insensibilização. O objetivo da insensibilização é evitar que a ave sofra durante a sangria.

As aves são então sangradas por um corte na base da mandíbula, percorrem um túnel por cerca de três minutos, tempo este necessário para uma sangria eficiente, e entram na seção de escaldagem e depenagem.

A escaldagem consiste na imersão das aves em tanques com água aquecida, que provoca a abertura dos folículos da pele onde estão fixadas as penas. Assim que deixam os

tanques passam pelas depenadeiras, que consistem de mancais de pratos com dedos de borracha girando em alta velocidade e retirando as penas.

Após esta etapa as aves são evisceradas e inspecionadas, e seguem para o resfriamento. Este pode ser feito a seco e por imersão em água gelada, ou ainda pela associação dos dois. O processo a seco consiste em fazer as carcaças evisceradas, penduradas em uma nórea, percorrerem um ambiente à baixa temperatura (*air chiller*), até que atinjam a temperatura desejada (Figura 02). Na imersão em água gelada utilizam-se grandes tanques (*chillers*) para se conseguir o tempo de imersão necessário. A temperatura das carcaças deve ser menor que 4°C após o resfriamento.

O resfriamento a seco não é utilizado no Brasil, pois provoca uma quebra de 3 a 4% na massa da carcaça por perda de água (saem do *air chiller* com massa menor que o que tinham na entrada).




Figura 02 – Foto de um Air Chiller. Fonte: Catálogo Linco

## 2.2 Resfriamento por imersão

Os tanques de imersão consistem em meios-cilindros deitados, dotados de um helicóide interno, que se move lentamente provocando o deslocamento das carcaças (Figuras 03 e 04). O processo deve ser feito no mínimo em duas etapas (pré-chiller e chiller), para atender o determinado pela legislação (MAPA, Portaria 210, 1998).




Figura 03 – Desenho em corte transversal de um chiller.




Figura 04 – Chiller de resfriamento com água.

Uma renovação mínima e constante de água deve ser cumprida, e também parâmetros de temperatura. Nos pré-chillers é necessária a adição de mais de 1,5 L de água por carcaça, e a temperatura no ponto mais quente não deve ultrapassar 16°C. Nos chillers é necessário no mínimo 1 L/carcaça, e a temperatura da água na saída do frango deve ser menor que 4°C. Utiliza-se para renovação água gelada numa temperatura próxima de 1°C, resfriada em trocadores de calor, normalmente de placas.

Para acelerar a troca térmica entre o frango e a água utilizam-se normalmente dois artifícios. Os chillers possuem camisas com circulação de uma solução de propilenoglicol,



numa temperatura abaixo de 0°C, e se adiciona gelo em escamas em pontos dispersos. A Figura 05 mostra um chiller onde pode se ver a mangueira de transporte de gelo (bombeado juntamente com água) e uma quantidade de gelo sobrenadante. A Figura 06 mostra a vista superior de um corte de uma camisa de propilenoglicol. O sentido do glicol dentro da camisa é sempre contrário ao deslocamento das carcaças, e as chicanas forçam a solução a circular por toda a extensão das paredes. O propilenoglicol é utilizado normalmente numa concentração de 30%, que permite a solução chegar a -20°C sem congelar. Por ser um anticongelante barato, seguro e inerte para as tubulações é preferido entre os demais.



Figura 05 – Chiller com gelo sobrenadante.

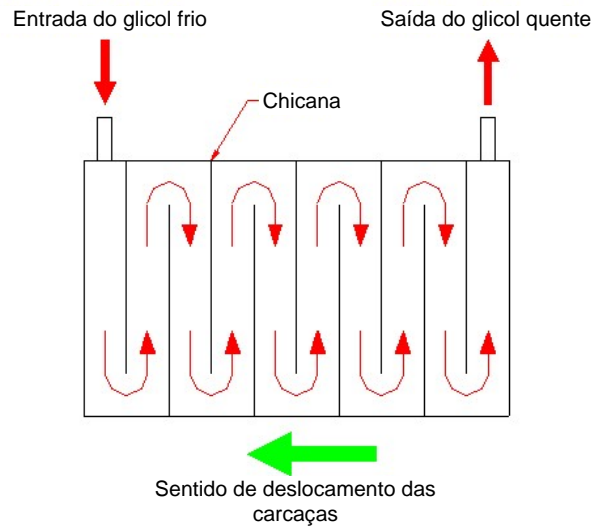


Figura 06 – Esquema de funcionamento das camisas de propilenoglicol.

Defini-se por carcaça um frango do qual foram removidas as penas, vísceras, sangue, pescoço, cabeça e pés. A densidade média da carcaça é de  $0,973 \text{ g/cm}^3$ , medidos experimentalmente pelo autor utilizando o princípio de Arquimedes. Isto faz com que as carcaças flutuem, e pelo deslocamento do helicóide, estas tendem a se acumular em apenas um lado dos chillers. A passagem da água de renovação se dará então pelo lado onde há menos carcaças, formando canais preferenciais e trocando pouco calor até chegar ao ladrão do esgoto. Para minimizar esta interferência provoca-se uma intensa movimentação da água borbulhando-se ar em pequenos furos por sob o tanque. A Figura 07 mostra a agitação da água provocada pelo borbulhamento.



Figura 07 – Chiller com agitação por borbulhamento de ar.

São diversas as variáveis que interferem no processo de resfriamento do frango em escala industrial, dentre elas:

- Massa inicial do frango;
- Velocidade do abate (frangos/hora);
- Temperatura inicial do frango;
- Tempo de retenção nos chillers, total e por módulo;
- Vazão da água de renovação em cada módulo;
- Temperatura da água de renovação;
- Vazão do propilenoglicol;
- Temperatura do propilenoglicol;
- Eficiência do borbulhamento;
- Temperatura do ar injetado;
- Massa de gelo adicionada, total e por módulo;
- Ponto de adição do gelo;
- Temperatura do gelo;
- Variáveis ambientais, como temperatura e umidade do ar;
- Variáveis de projeto, como espessuras e materiais de isolamento;
- Lavagem final das carcaças;
- Tempo de gotejamento;
- Sexo da ave;
- Alimentação;
- Abertura abdominal;
- Lesões por esforço na evisceração;
- Desnaturação protéica na escaldagem;
- Diferenças fisiológicas entre aves;
- Posição da carcaça dentro do chiller durante o resfriamento;
- Rompimento da pele.

De acordo com levantamentos estatísticos e estudos feitos pela empresa da constituição percentual de um frango vivo 74,3% é carcaça, e dentro de um mesmo lote encontra-se uma dispersão média de 12% entre o peso dos frangos. Estes números são influenciados pela idade do lote e pelo sexo. Frangos maiores apresentam um percentual maior de carcaça, e machos possuem mais massa muscular que fêmeas.

A velocidade do abate pode sofrer variações em função de problemas sanitários, rendimento das máquinas em cada faixa de peso, problemas com etapas anteriores (fomento, pendura, etc.) e posteriores ao abate (congelamento, embalagem, sala de cortes, etc.). Com esta variação de velocidade a temperatura das carcaças ao caírem nos chillers também se altera (a temperatura de um frango vivo é de 41°C). Além de que carcaças com menor massa perdem mais calor nos chuveiros, mas também ganham mais na escaldagem.

O tempo que as carcaças ficam retidas no sistema de resfriamento varia cerca de 5 minutos para cada hora de retenção. Isto quer dizer que, em chillers projetados para fornecer uma hora de resfriamento, durante o abate as primeiras carcaças sairão com 55 minutos, e as últimas com 65 minutos após terem caído nos chillers. Eventuais problemas em outras etapas do processo que resultem em paradas de abate invariavelmente irão aumentar o tempo de resfriamento.

Usualmente se trabalha com a solução de propilenoglicol entre -6 e -8°C. Temperaturas muito baixas ou vazões muito altas do propilenoglicol podem formar camadas de gelo nas paredes internas dos chillers, que dependendo da espessura podem até travar o helicóide e ocasionar a quebra do motorreductor. A concentração de 30% é necessária porque o regime de compressão utilizado para se resfriar a solução possui uma temperatura de evaporação do gás refrigerante de -20°C.

O borbulhamento influencia muito na redução dos canais preferenciais da água de renovação. Como complicador há o fato de que a corrente de ar se aquece no momento da compressão, levando uma quantidade de calor indesejado para os chillers. Para minimizar este efeito se utiliza água gelada para selagem das bombas. A distribuição do ar deve ser homogênea por todo o comprimento dos chillers.

A grande ferramenta para se alcançar o maior gradiente de temperatura nos tanques é a adição de gelo. Ele mantém a água uniformemente próxima de 0°C. O gelo é obtido em escamas e numa temperatura de aproximadamente -12°C. Ele é bombeado misturado com água gelada desde as fábricas até os chillers. A quantidade adicionada por módulo e o ponto de adição são variáveis importantes para se obter um maior aproveitamento energético e a maior eficiência dos tanques.

Além disto, o resfriamento também é influenciado por variáveis ambientais e de projeto. Temperatura, umidade ambiente, correntes de ar, espessura de isolamentos e área da lâmina de água são algumas variáveis que influenciam na perda de calor do sistema para as vizinhanças.

O tempo de gotejamento das carcaças desde a saída dos chiller até serem embaladas ou processadas influencia na quantidade de água retida. Quanto mais tempo ficarem gotejando mais água perdem. O que determina este tempo é a distância a ser percorrida na nória, ou seja, a distância entre as diversas seções.

O tipo de alimentação da ave altera a composição dos tecidos, influenciando na velocidade da absorção da água durante a imersão. O tamanho da abertura abdominal e lesões na pele aumentam a área de contato dos músculos com a água.

Um aquecimento excessivo na escaldagem provoca a desnaturação das proteínas da pele e da superfície do músculo formando uma espécie de isolamento entre a água e o restante do músculo.

Desta forma fica evidente a complexidade da modelagem fenomenológica deste processo. Muitos dos fenômenos presentes teriam que ser desconsiderados e muitas idealizações assumidas para se obter um modelo, que de qualquer maneira seria extremamente complexo, de solução muito difícil, e de resposta duvidosa em função das idealizações.

CARCIOFI & LAURINDO (2007) estudaram alguns parâmetros do processo de resfriamento de carcaças buscando quantificar a importância destes na retenção de água pelas carcaças. Seus resultados indicam que a temperatura da água, tempo de resfriamento, pressão hidrostática e agitação da água são determinantes na quantidade de água absorvida.

JAMES *et al* (2006) relacionaram a influência do tempo de imersão, temperatura da água e quantidade de gelo sobre diversos parâmetros do resfriamento, entre eles a temperatura final e a quantidade de água absorvida pelas carcaças. Fizeram também comparações entre o resfriamento por imersão e por *air-chiller*, considerando além dos aspectos acima a carga microbiana e contaminação cruzada das carcaças, aspecto, sabor, textura e custos de operação. Foram avaliados tempos entre 25 e 165 minutos, com e sem adição de gelo, com carcaças variando entre 0,9 e 3,2 kg. Segundo os autores o tempo de residência e o grau de agitação da água são os grandes responsáveis pela retenção da umidade. O percentual de gelo adicionado à água afeta tanto a temperatura final como a absorção.

SAVELL (*et al*, 2004) fez uma análise do impacto do resfriamento em produtos cárneos, avaliando parâmetros de qualidade como declínio do pH, maciez, carga microbiana, encurtamento pelo frio e vida de prateleira; estudou a influência do tempo e da taxa de resfriamento. ALLEN (*et al*, 2000) comparou seis sistemas comerciais de resfriamento de carcaças de frango com relação a parâmetros que afetam a carga microbiana final. Seus resultados mostram que o resfriamento por imersão em água gelada é o que mais reduz uma contaminação inicial alta, mas também o que mais provoca contaminação cruzada.

WANG & SUN (2001) avaliaram a performance do resfriamento de carne cozida por ar lento, ar rápido e por imersão em água, utilizando o método dos elementos finitos. Para diferentes geometrias de produtos foram determinadas as condições ideais de operação e qual dos métodos seria o mais adequado.

DYER (2007) descreve ser de grande importância a temperatura e o tempo de escaldagem na capacidade de retenção de água das carcaças. Como os tanques de escaldagem possuem um tamanho fixo o tempo passa a ser função apenas da velocidade da linha. Fala também sobre os efeitos do borbulhamento, tanto buscando aumentar o coeficiente de transferência de calor do frango para a água, como também influenciando na retenção de umidade.

Dufour, citado por CARCIOFI & LAURINDO (2007), explica o fenômeno da retenção de água. Durante a imersão, as carcaças retêm a água que entra nos espaços intercelulares criados durante o *rigor mortis*. Os caminhos para entrada da água são os contatos direto desta com os músculos, ou a penetração pelos poros da pele, conforme mostrado na figura 08.

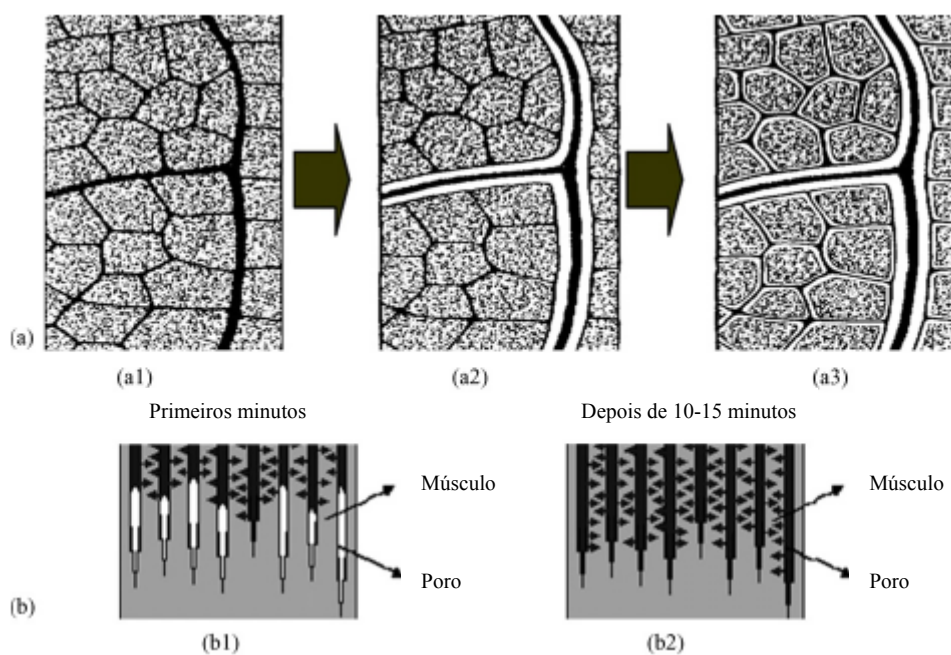


Figura 08 – Mudanças que ocorrem nos músculos das aves *post mortem*. (a1) representa a seção de um músculo imediatamente após a sangria; (a2) alguns minutos *post mortem*; (a3) músculo já em *rigor mortis*. (b1) representa o modelo físico da entrada de água na carcaça no primeiro passo da absorção, controlado pelo mecanismo hidrodinâmico; (b2) segundo passo da absorção, quando os poros estão parcialmente cheios de água. Fonte: CARCIOFI & LAURINDO (2007).

O limite brasileiro para absorção de água é de 8%, já para a União Européia (UE) este limite é de 4,5%. A temperatura máxima das carcaças após o resfriamento na regulamentação da UE é de 4°C. Na legislação brasileira as carcaças não devem passar de 7°C (tolera-se 10°C para congelamento imediato). Porém, apesar da legislação nacional ser mais branda para estes dois parâmetros, grande número dos frigoríficos nacionais usam os parâmetros europeus como limite, pois só assim conseguem liberação para exportar para este mercado, que é economicamente mais atrativo.

Uma informação importante sobre o limite de absorção é que, no caso da UE, se refere apenas para carcaças vendidas inteiras, e não para cortes. No caso dos cortes se utiliza uma relação entre os percentuais de umidade e proteína, com limites especificados para cada produto. Porém, no Brasil qualquer extrapolação do limite é considerada fraude, independente do destino.

## **2.3 Modelagem convencional**

### **2.3.1 Modelagem do resfriamento**

A predição do tempo de resfriamento dos produtos e a caracterização de parâmetros do processo de transferência de calor têm sido estudadas ao longo de muitos anos. O objetivo comum desses estudos é desenvolver um método simples de predição, que requeira uma quantidade mínima de dados e um programa computacional adequado (TERUEL *et al*, 2001).

A modelagem fenomenológica do processo de resfriamento por imersão é representada pela equação da difusão que se trata de uma equação diferencial parcial que apresenta dependência funcional com o tempo e com o espaço. Para resolver este sistema de equações geralmente empregam-se métodos numéricos, tais como: diferenças finitas, volumes finitos e elementos finitos.

Existem na literatura diversos trabalhos que tem utilizado modelos fenomenológicos para o resfriamento e congelamento de frutas, tais como TERUEL (*et al*, 2001) e TERUEL (*et al*, 2003). Entretanto, são raros os trabalhos publicados modelando o resfriamento de carcaças de frango, principalmente devido a uma geometria não definida das carcaças e da não homogeneidade (cartilagens, ossos, pele, músculo, etc.). Deve-se destacar também que os trabalhos que são apresentados na literatura referem-se ao processo de resfriamento em escala laboratorial.

NEVES FILHO (1978) resolveu um modelo bastante simplificado da temperatura após o resfriamento, utilizando de muitas idealizações e eliminando do modelo parâmetros como borbulhamento e adição de gelo. Seus resultados dentro destas idealizações são muito precisos.

$$\frac{\partial T}{\partial t} = \alpha \frac{\partial^2 T}{\partial x^2} \quad (01)$$

onde:

T = temperatura do corpo;

t = tempo de resfriamento;

$\alpha$  = difusividade térmica do sistema;

x = espessura do corpo.

com as seguintes condições de contorno:

$$-k \left. \frac{\partial T}{\partial x} \right|_{x=0} = h(T - T_{\text{água}})$$

e

$$-k \left. \frac{\partial T}{\partial x} \right|_{x=L} = h(T - T_{\text{água}})$$

Este modelo leva em conta apenas o tempo de imersão, temperatura da água, espessura do músculo e características dos materiais.

Um modelo simplificado para prever a temperatura de resfriamento pode ser obtido considerando que a transferência de calor por condução é rápida, a massa e a capacidade calorífica são constantes, neste caso, pode-se representar a transferência de calor pela seguinte equação:

$$mC_p \frac{dT}{dt} = ha(T - T_a) \quad (02)$$

Com a seguinte condição inicial: em  $t = 0$ , tem-se que:  $T(0) = T_i$ . A solução analítica da Eq. (02) é dada pela seguinte equação:

$$T_f = T_a + (T_i - T_a) e^{-\frac{k}{m}t} \quad (03)$$

onde:

$T_f$  = temperatura final do corpo [K];

$T_a$  = temperatura do ambiente onde está o corpo [K]

$T_i$  = temperatura inicial do corpo [K];

$k = (ha / C_p) =$  constante experimental [ $\text{min}^{-1}$ ];



t = tempo de resfriamento [min]

Este modelo simplificado leva em conta a temperatura inicial do material, a temperatura do fluido refrigerante, a massa inicial e o tempo de resfriamento. Não foram encontrados trabalhos de resfriamento de carcaças de frango utilizando a Lei de Newton do Resfriamento.

### 2.3.2 Modelagem da absorção de água

O processo de absorção da água pela carcaça de frango pode ser representado pela segunda Lei de Fick, entretanto, nesta equação o coeficiente de difusão é função da temperatura. Portanto, é necessário que seja resolvida simultaneamente a equação da difusão de massa e energia, o que aumenta muito a complexidade do problema.

CARCIOFI e LAURINDO (2007) investigaram a absorção de água por carcaças de frangos em chiller numa escala piloto. Estudaram a influência do método de agitação da água, temperatura da água, intensidade da agitação e pressão hidrostática. Estes autores propuseram um modelo empírico para descrever a variação de massa das carcaças que considerava as características do material e o tempo de imersão, descrito pela seguinte equação:

$$\frac{dW}{dt} = K_0 e^{\beta W} (W_m - W) \quad (04)$$

onde:

W = fração de água na carcaça [kg/kg];

W<sub>m</sub> = fração máxima de água na carcaça [kg/kg];

K<sub>0</sub> = constante experimental [min<sup>-1</sup>];

β = constante experimental [kg/kg]

t = tempo de imersão [min]

Os erros encontrados por CARCIOFI e LAURINDO (2007) na aplicação deste modelo nos dados experimentais ficaram na faixa de 5 a 8%.

### 2.4 Modelagem por redes neurais e uso na indústria

Redes Neurais Artificiais (RNA's) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neuronal de organismos inteligentes e que adquirem conhecimento através da experiência. Uma grande Rede Neural Artificial pode ter

centenas ou milhares de unidades de processamento, já os cérebros dos animais podem ter muitos bilhões de neurônios (BRAGA *et al*, 2000).

As RNA's podem ser utilizadas na resolução de uma grande classe de problemas dos mais diversos tipos: classificação, identificação, diagnóstico, análise de sinais e de imagens, otimização e controle, etc. As Redes Neurais na maioria dos casos são de fácil implementação, robustas no tratamento de dados com ruído e eficientes, especialmente nos problemas em que não se tem formulação analítica ou não se tem um conhecimento explícito acessível ou os dados "estão contaminados" por ruído ou o próprio problema modifica-se com o tempo (BRAGA *et al*, 2000). O emprego de uma Rede Neural depende da habilidade em adaptá-la ao problema considerado, por meio de mudanças nos pesos sinápticos (aprendizagem), de modo a aumentar sua eficiência.

As redes neurais artificiais foram desenvolvidas originalmente na década de 40, pelo neurofisiologista Warren McCulloch, do Massachusetts Institute of Technology, e pelo matemático Walter Pitts, da Universidade de Illinois, os quais, dentro do espírito cibernético, fizeram uma analogia entre células nervosas vivas e o processo eletrônico num trabalho publicado sobre "neurônios formais". O trabalho consistia num modelo de resistores variáveis e amplificadores representando conexões sinápticas de um neurônio biológico, conforme descrito por GALKIN (2007).

Desde então, mais enfaticamente a partir da década de 80, diversos modelos de redes neurais artificiais têm surgido com o propósito de aperfeiçoar e aplicar esta tecnologia. Algumas destas propostas tendem a aperfeiçoar mecanismos internos da rede neural para aplicação na indústria e negócios, outras procuram aproximá-las ainda mais dos modelos biológicos originais (ELIAS, 2007).

#### **2.4.1 Redes Neurais Artificiais e o Neurônio Biológico**

A célula nervosa, ou, simplesmente, neurônio, é o principal componente do sistema nervoso. Estima-se que no cérebro humano existam aproximadamente 15 bilhões destas células, que são responsáveis por todas as funções do sistema.

Existem diversos tipos de neurônios, com diferentes funções dependendo da sua localização e estrutura morfológica, mas em geral constituem-se dos mesmos componentes básicos:

- O corpo do neurônio, constituído do núcleo, que dá suporte metabólico a toda célula;

- O axônio (fibra nervosa), prolongamento único e grande que aparece no corpo. É responsável pela condução do impulso nervoso para o próximo neurônio, podendo ser revestido ou não por mielina;
- Os dendritos, que são prolongamentos menores em forma de ramificações que emergem do corpo e do final do axônio, sendo, na maioria das vezes, responsáveis pela comunicação entre os neurônios através das sinapses.

A Figura 09 representa um neurônio e seus principais constituintes.

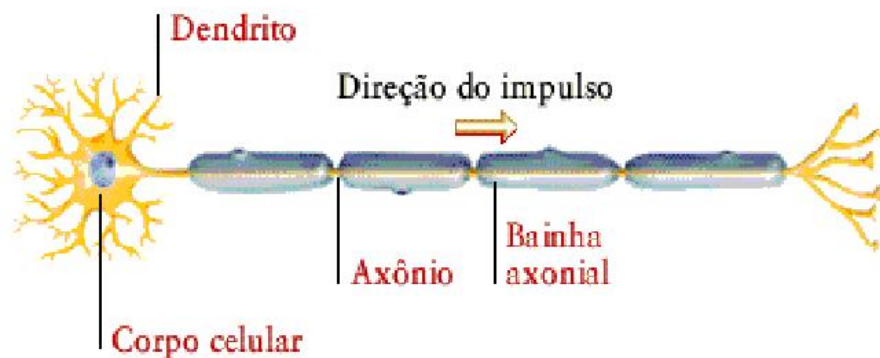


Figura 09 – Estrutura básica de um neurônio e suas partes.

O sistema nervoso é constituído basicamente por um conjunto extremamente complexo de células nervosas, que se interconectam de forma específica e precisa, formando os chamados circuitos neurais.

A plasticidade neural é a capacidade de organização do sistema nervoso frente ao aprendizado. Esta organização se relaciona com a modificação de algumas conexões sinápticas. Os processos de modificação são consequência da interação com o meio ambiente (TAFNER, 2008).

A plasticidade neural é a propriedade do sistema nervoso que permite o desenvolvimento de alterações estruturais em resposta à experiência, e como adaptação a condições mutantes e a estímulos repetidos. A “aprendizagem” pode levar a alterações estruturais no cérebro. A cada nova experiência do indivíduo, portanto, redes de neurônios são rearranjadas, outras tantas sinapses são reforçadas e múltiplas possibilidades de respostas ao ambiente tornam-se possíveis. O mapa cortical de um adulto está sujeito a constantes modificações com base no uso ou atividade de seus caminhos sensoriais periféricos.

Os estímulos nervosos são transmitidos de um neurônio para outro por meio de junções interneuronais, denominadas sinapses. O comportamento de uma sinapse química

pode ser resumido da seguinte maneira: quando um potencial de ação chega a um terminal pré-sináptico, a despolarização da membrana pode fazer com que um pequeno número de vesículas sinápticas secretem um composto químico denominado neurotransmissor na fenda sináptica, que por sua vez, irá atuar nas proteínas receptoras do neurônio seguinte produzindo alterações na permeabilidade da membrana neuronal pós-sináptica, podendo excitá-lo, inibi-lo ou modificar de alguma forma sua intensidade.

O potencial de ação de intensidade e duração definidas é provocado em um neurônio pelo efeito combinado de todos os estímulos excitatórios e inibitórios que chegam até ele (integração sináptica), e por uma despolarização que seja suficientemente significativa para atingir o limiar de secreção dos neurotransmissores (ELIAS, 2007).

O sistema nervoso detecta estímulos externos e internos, tanto físico quanto químico, e desencadeia as respostas musculares e glandulares. Assim, é responsável pela integração do organismo com o seu meio ambiente. Em alguns seres vivos, a formação deste potencial pós-sináptico aproxima-se simplesmente de uma soma algébrica destes estímulos.

#### 2.4.2 Redes Neurais Artificiais como Ferramenta Computacional

O neurônio artificial é uma estrutura lógico-matemática que procura simular a forma, o comportamento e as funções de um neurônio biológico. Assim sendo, os dendritos foram substituídos por entradas, cujas ligações com o corpo celular artificial são realizadas através de elementos chamados de peso (simulando as sinapses). Os estímulos captados pelas entradas são processados pela função de soma, e o limiar de disparo do neurônio biológico foi substituído pela função de transferência. A Figura 10 apresenta um neurônio artificial e seus constituintes.

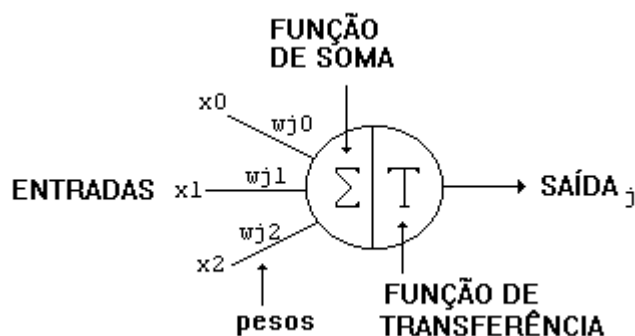


Figura 10 - Constituintes do neurônio artificial.

Combinando diversos neurônios artificiais se pode formar o que é chamado de rede neural artificial. As entradas, simulando uma área de captação de estímulos, podem ser conectadas em muitos neurônios, resultando, assim, em uma série de saídas, onde cada neurônio representa uma saída. Essas conexões, em comparação com o sistema biológico, representam o contato dos dendritos com outros neurônios, formando assim as sinapses. A função da conexão em si é tornar o sinal de saída de um neurônio em um sinal de entrada de outro, ou ainda, orientar o sinal de saída para o mundo externo (mundo real). As diferentes possibilidades de conexões entre as camadas de neurônios podem gerar n números de estruturas diferentes.

Matematicamente, os valores de ativação para cada neurônio são a soma das informações recebidas multiplicadas pelos pesos correspondentes:

$$\alpha_{a_i} = \sum_{j=1}^Z w_{i,j} \cdot x_j \quad (05)$$

onde:

$\alpha_{a_i}$  = valor de ativação do neurônio  $i$  da camada  $a$ ;

$w_{i,j}$  = peso da fonte  $j$  em relação ao neurônio  $i$ ;

$x_j$  = variável de alimentação no neurônio;

$Z$  = número de alimentações do neurônio.

Com relação à função de transferência, esta pode ter muitas formas e métodos, como descrito por FRANCISCO (2000). Destacam-se as funções sigmoidal e tangente hiperbólica, pelo seu formato em “S” alongado, sendo contínuas, crescentes e limitadas por duas assíntotas horizontais. Também se utiliza uma função linear, por apresentar resultados maiores que a unidade. Matematicamente:

Tangente hiperbólica:  $o_{a_i} = \tanh(\alpha_{a_i})$

Sigmóide:  $o_{a_i} = \frac{1}{1 + e^{-\alpha_{a_i}}}$

Linear:  $o_{a_i} = \alpha_{a_i}$

onde  $o_{a_i}$  e a função de transferência do neurônio  $i$  da camada  $a$ .

A rede neural deve possuir no mínimo duas camadas de neurônios, a de entrada de dados e a da saída dos resultados. Assim, a resposta da rede seria o resultado da aplicação dos valores de ativação na função de transferência da camada de saída.

Como a rede apresenta desempenho muito limitado com somente duas camadas (TATIBANA & KAETSU, 2007), a adição de uma camada intermediária (ou oculta) faz-se necessária. Neste tipo de configuração, cada neurônio está ligado com todos os outros das camadas vizinhas, mas neurônios da mesma camada não se comunicam, além da comunicação ser unidirecional, apresentando assim um comportamento estático (BRAGA et al, 2004).

Com apenas uma camada oculta já é possível calcular uma função arbitrária qualquer a partir de dados fornecidos. Independente de cada abordagem, quanto mais camadas de neurônios, melhor é o desempenho da rede neural, pois aumenta a capacidade de aprendizado, melhorando a precisão com que ela delimita regiões de decisão. Estas regiões de decisão são intervalos fixos onde a resposta pode estar (TATIBANA & KAETSU, 2007). Na Figura 11 é representada uma rede com três camadas, sendo uma oculta.




Figura 11 – Arquitetura em camadas de uma rede neural.

Quando se trabalha com redes neurais, o grande desafio é encontrar quais os pesos adequados para o fenômeno em estudo. O ajustamento destes pesos entre as conexões, estabelecendo as relações entre as variáveis de entrada e saída, é chamado de treinamento da rede, dando à rede a capacidade de “aprender” o que ocorre no processo (ANTONELLI, 1998).

MEDEIROS (2006) fez uma revisão de aspectos avançados em RNA. Cita a tangente hiperbólica e as funções sigmoidais como as mais utilizadas para funções de transferência. Discute também o número de neurônios em cada camada da rede. Concluiu que uma rede neural com três camadas, sendo uma oculta, pode modelar qualquer função matemática

contínua através de uma rede com  $2n+1$  neurônios ocultos, sendo  $n$  o número de neurônios da camada de entrada. Para redes com quatro camadas, duas ocultas, apresentam melhor desempenho quando são treinadas com uma proporção de 3:1 entre o número de neurônios da primeira camada oculta e o número de neurônios da segunda camada oculta, e que esta deverá conter o dobro do número de neurônios da camada de saída.

FUJITA (2001) estudou vários trabalhos sobre métodos de análise de significância das variáveis de entrada sobre as respostas das RNA. Um método recomendado baseia-se na correlação  $R_j$  entre os valores experimentais e os previstos para a variável  $j$ , conforme equação abaixo:

$$R_j = \frac{N \left[ \sum_{i=1}^N (x_i - \mu_x)(y_i - \mu_y) \right]}{\sqrt{\left[ N \sum_{i=1}^N x_i^2 - \left( \sum_{i=1}^N x_i \right)^2 \right] \left[ N \sum_{i=1}^N y_i^2 - \left( \sum_{i=1}^N y_i \right)^2 \right]}} \quad (06)$$

onde:

$N$  é o número de dados utilizados;

$x_i$  é o valor calculado para a  $j$ -ésima variável;

$y_i$  é o valor experimental para a  $j$ -ésima variável;

$\mu_x$  é a média dos valores calculados pela rede neural;

$\mu_y$  é a média dos valores experimentais;

$N_V$  é o número de variáveis de entrada da rede.

A análise da sensibilidade é efetuada pelo estudo do efeito da eliminação de uma variável de entrada no índice de correlação do modelo, em relação ao índice de correlação da rede treinada com todas as variáveis de entrada, conforme equação abaixo:

$$I_j = 1 - \frac{R_j}{R_N} \quad (07)$$

onde  $R_N$  é o índice de correlação entre os valores experimentais e os valores calculados para o caso base.

GOÑI *et al* (2008) empregaram redes neurais artificiais e algoritmos genéticos para prever o tempo de congelamento e descongelamento de diversos alimentos com variadas geometrias. As variáveis de entrada eram o fator de forma, características dimensionais, número de Biot, difusividade térmica, e as temperaturas inicial, final e do ambiente. Seus resultados mostram que as redes tiveram um erro médio menor que 10%, sugerindo que o método é simples e preciso para prever os tempos de congelamento e descongelamento para um amplo grupo de alimentos de diversos tamanhos, formas e condições de trabalho

MITTAL & ZHANG (2002) também usaram redes neurais artificiais para prever parâmetros térmicos no processamento de alimentos. Prevendo a taxa de aquecimento necessária para a esterilização os erros encontrados ficaram abaixo de 16%.

Em outro trabalho, MITTAL & ZHANG (2000) aplicaram redes neurais artificiais para prever o tempo de congelamento de alimentos de formatos variados. A espessura do produto, largura, comprimento, coeficiente de transferência de calor convectivo, condutividade térmica do produto congelado, densidade, calor específico do produto não congelado, quantidade de água no produto, temperatura inicial e a temperatura ambiente foram utilizadas como variáveis de entrada. Os resultados mostram que o método se mostrou simples, conveniente e preciso, prevendo o tempo de congelamento com um erro menor que 10%.

QIAO *et al* (2007) utilizaram processamento de imagens e redes neurais artificiais para prever propriedades mecânicas de nuggets de frango fritos. Os parâmetros de textura de interesse foram medidos, e as variáveis de entrada eram o tempo de fritura e cinco diferentes imagens do produto. O coeficiente de correlação entre os valores reais e previstos ficaram acima de 0,84, demonstrando que o método é eficiente. Uma grande vantagem do diagnóstico por imagem é que a análise é não-destrutiva.

## **2.5 Modelos utilizados para treinar a rede**

A etapa de treinamento é uma das mais importantes na formulação de um modelo com base em RNA. Há basicamente dois tipos de treinamento, o supervisionado e o não-supervisionado (FUJITA, 2001).

### **2.5.1 Treinamento não-supervisionado**

Também conhecido como autônomo ou auto-organizado. Neste método não há intervenção de um supervisor e nem há um vetor projetado de saída. O algoritmo de treinamento necessita apenas vetores de entrada, modificando os pesos para produzir vetores de saída consistentes. O processo de treinamento extrai propriedades estatísticas do conjunto treinado e grupo de vetores similares entre classes. São exemplos o método de Rosenblat e a Regra Delta de Widrow (KOVÁCS, 2002).



## 2.5.2 Treinamento supervisionado

Neste caso há um supervisor que avalia o comportamento do sistema e providencia as modificações subseqüentes. Pares são formados de cada vetor de entrada com um vetor alvo de saída. Juntos são chamados “par treinado”. Um vetor de entrada é aplicado, a saída da rede é calculada e comparada ao vetor alvo. O erro adquirido é retropropagado através da rede e os pesos são mudados conforme o algoritmo de treinamento escolhido que tende a minimizar o erro. Os vetores do treinamento são aplicados seqüencialmente, os erros são calculados para cada par treinado e os pesos ajustados para cada vetor até que o erro de toda a rede atinja um valor aceitável. Por este motivo estes métodos são também conhecidos como métodos de correção do erro. Os métodos de otimização matemática se enquadram nesta classe.

A etapa seguinte, depois de a rede estar treinada, é descobrir se esta realmente aprendeu como o processo funciona, ou se apenas se ajustou aos pontos informados. Esta etapa é denominada validação da rede, e é feita com um segundo conjuntos de vetores de entrada, desconhecidos até então pela rede, para os quais se calculam as respostas, sendo estas comparadas com as respostas reais. Caso o grau de precisão na previsão seja igual ou próximo do obtido durante o treinamento, pode-se afirmar que o treinamento está validado.

## 2.6 Métodos de otimização

Os métodos de otimização matemática foram criados com o objetivo de permitirem se encontrar os máximos e mínimos de uma função que dependa de uma ou mais variáveis independentes. As tarefas de minimizar ou maximizar uma função são basicamente as mesmas, pois o máximo de uma função  $f(x)$  será o mínimo de  $-f(x)$ .

Como mostrado na Figura 12, os extremos de uma função (pontos de máximo e mínimo) num determinado intervalo podem ser locais (o maior ou menor valor de uma vizinhança finita, mas não o limite da vizinhança) ou globais (verdadeiramente o maior ou menor valor da função). Em geral, achar um extremo global é um problema muito difícil. Na figura os pontos A, C e E são máximos locais, e G o máximo global; B e F são mínimos locais, e D o mínimo global.




Figura 12 – Extremos de uma função em um intervalo. Fonte: PRESS *et al* (1992)

Os métodos de otimização estudados no presente trabalho são o Simplex, o método de Powell e a *Simulated Annealing*.

### 2.6.1 Método Simplex

O método simplex de Nelder & Mead é uma técnica simples de busca direta que é utilizada em problemas de otimização. Uma busca direta significa que o método é guiado somente pelo cálculo do valor da função em vários pontos e não necessita da avaliação da primeira e segunda derivadas (parcial) da função a ser otimizada. O método simplex “mantém” diversos pontos diferentes. Ele escolhe estes pontos de forma determinística, configurando um politopo e forma a “repelir” soluções inadequadas.

### 2.6.2 Método de Powell

Muitos métodos para a solução de problemas sem restrição são desenvolvidos para minimizar funções quadráticas, embora a maior parte dos problemas tenham funções que não sejam quadráticas. Isso porque toda função pode ser bem aproximada por uma função quadrática próxima do mínimo. Esse é o caso do método de Powell. Nesse método, a cada passo a função a ser minimizada é aproximada localmente por uma função quadrática, dada por:

$$f(x) = \frac{1}{2}x^T Qx + b^T x + c \quad (08)$$

Considere agora um conjunto de direções  $s_i$ ,  $i=1, 2 \dots Q$ -conjugadas linearmente independentes, ou seja:

$$s_i^T Q s_j = 0 \text{ para } i \neq j$$

Pode ser mostrado que: "se  $f$  for minimizada ao longo de cada direção  $s$  definida acima, então o mínimo de  $f$  será encontrado no (ou antes) do  $n$ -ésimo passo independentemente do ponto inicial, dado que erros de arredondamento não sejam acumulados", onde  $n$  é o número de variáveis. É importante que as direções sejam linearmente independentes (como definido acima) caso contrário não há convergência para o mínimo (SILVA, S.d.).

### **2.6.3 Simulated Annealing**

O desenvolvimento do "Simulated Annealing" (SA) ou recozimento simulado é baseado num fenômeno de mecânica estatística relacionado com o equilíbrio de um grande número de átomos em sólidos e líquidos numa certa temperatura. Esse fenômeno é observado na solidificação de metais, onde um número de estados sólidos com diferentes estruturas atômicas internas que correspondem a diferentes níveis de energia que podem ser atingidos dependendo da taxa de resfriamento. Assim se o resfriamento é rápido, o estado sólido resultante tende a ter uma pequena margem de estabilidade porque os átomos irão assumir posições na estrutura cristalina de forma a atingir um nível de energia que corresponde a um mínimo local. Para atingir um nível de energia mais estável (correspondente a um mínimo global), o processo de recozimento é usado onde o metal é reaquecido até uma alta temperatura e resfriado lentamente, dando tempo suficiente aos átomos para encontrar posições que minimizem a energia potencial.

### **3. MODELAGEM MATEMÁTICA**

#### **3.1 Esquema do processo a ser modelado**

O processo de resfriamento da unidade da SADIA-Toledo é constituído de três chillers em série, todos com diâmetro de 2,5 m. Na linha de abate onde foram coletados os dados o primeiro módulo possui 9 m de comprimento, o segundo 12 m e o terceiro 24 m. O segundo e terceiro módulos possuem camisas de propilenoglicol, e todos possuem borbulhamento de ar. É feita adição de gelo em todos os módulos.

Um esboço do sistema, com a relação das variáveis envolvidas, é apresentado na Figura 13.

#### **3.2 Variáveis de entrada e saída**

Conforme mostrado na Figura 13, foram definidas 25 variáveis de entrada, sendo elas:

- X<sub>1</sub>: temperatura da escaldagem [°C];
- X<sub>2</sub>: velocidade de abate [aves/h];
- X<sub>3</sub>: temperatura ambiente [°C];
- X<sub>4</sub>: tempo de retenção no pré-chiller [minutos];
- X<sub>5</sub>: temperatura da água no início do pré-chiller [°C];
- X<sub>6</sub>: temperatura da água no final do pré-chiller [°C];
- X<sub>7</sub>: intensidade do borbulhamento no pré-chiller [adimensional];
- X<sub>8</sub>: quantidade de gelo no pré-chiller [adimensional];
- X<sub>9</sub>: vazão de renovação do pré-chiller [L/carcaça];
- X<sub>10</sub>: massa inicial da carcaça [g];
- X<sub>11</sub>: temperatura inicial da carcaça [°C];
- X<sub>12</sub>: tempo de retenção no chiller 1 [minutos];
- X<sub>13</sub>: temperatura da água no início chiller 1 [°C];
- X<sub>14</sub>: temperatura da água no final do chiller 1 [°C];
- X<sub>15</sub>: intensidade do borbulhamento no chiller 1 [adimensional];
- X<sub>16</sub>: temperatura do propilenoglicol no chiller 1 [°C];
- X<sub>17</sub>: quantidade de gelo no chiller 1 [adimensional];
- X<sub>18</sub>: vazão de renovação do chiller 1 [L/carcaça];
- X<sub>19</sub>: tempo de retenção no chiller 2 [minutos];




Figura 13 – Fluxo do processo em estudo.

- X<sub>20</sub>: temperatura da água no início chiller 2 [°C];
- X<sub>21</sub>: temperatura da água no final do chiller 2 [°C];
- X<sub>22</sub>: intensidade do borbulhamento no chiller 2 [adimensional];
- X<sub>23</sub>: temperatura do propilenoglicol no chiller 2 [°C];
- X<sub>24</sub>: quantidade de gelo no chiller 2 [adimensional];
- X<sub>25</sub>: vazão de renovação do chiller 2 [L/carcaça].

A quantidade de gelo e a intensidade do borbulhamento em cada módulo foram adimensionalizadas considerando-se como 0 quando completamente ausentes, e como 5 quando na capacidade máxima (para se ter uma escala e intensidades).

Como variáveis respostas foram estudadas a temperatura das carcaças após o resfriamento (Y<sub>1</sub>, [°C]) e a massa final das carcaças (Y<sub>2</sub>, [g]). Foram medidos também, sem objetivo específico de previsão, a temperatura e a massa após o primeiro e o segundo módulos do sistema de resfriamento.

Estas variáveis foram escolhidas com base nos trabalhos já publicados sobre o assunto, como citado anteriormente, e na experiência prática do autor. As demais variáveis citadas como possivelmente influentes não foram avaliadas por serem de difícil medição, e serão consideradas como ruídos.

### **3.3 Coleta de dados**

Durante o período da coleta de dados 92% dos frangos abatidos eram da linhagem Cobb, sendo que nesta linha eram exclusivamente machos.

Depois de definidas as variáveis de entrada e saída, foi elaborada um planilha de coleta de dados para registro das informações. Foi definido como tamanho de cada amostra um conjunto de 13 carcaças, considerado como adequado por garantir que no mínimo 10 chegassem ao final do sistema de resfriamento sem perder os lacres de identificação (uma das pernas do frango recebe um lacre plástico numerado nesta coleta), e que para um número maior de carcaças apenas uma pessoa não conseguiria realizar a coleta.

Para medição da temperatura foi utilizado um termômetro digital marca Testo, modelo 106-T2, com precisão de 0,1°C. A pesagem foi feita em balança digital marca Toledo, com precisão de 1g. Tanto o termômetro quanto a balança foram calibrados no laboratório de metrologia da empresa, e apresentavam desvio menor que o máximo recomendado pelos fabricantes.

De posse dos instrumentos de medida e da planilha de coleta, foi treinado um funcionário para que realizasse as coletas. As carcaças eram retiradas dos ganchos antes de caírem nos chillers, e acondicionadas em caixas plásticas. Na seqüência eram pesadas e tinham a temperatura inicial medida, e recebiam um lacre plástico contendo um número de identificação. Depois de todas as medições feitas as carcaças eram então jogadas no primeiro módulo do sistema de resfriamento. Neste mesmo momento era anotada a hora, a temperatura da água no início do módulo, a vazão da água de renovação, a intensidade do borbulhamento e a quantidade de gelo adicionada. O peso e a temperatura eram medidos individualmente.

O procedimento para medição da temperatura consiste em inserir a ponteira do termômetro na região do peito do frango, perpendicular ao músculo, penetrando o suficiente para que a ponteira atinja o centro do músculo peitoral. Esta é a região mais espessa da musculatura do frango e por este motivo é considerada como ponto padrão para aferição da temperatura.

No momento em que as carcaças passavam de um módulo para o outro eram novamente pesadas e tinham a temperatura medida. Anotavam-se os demais parâmetros como descrito anteriormente, até que passassem por todo o sistema de resfriamento, momento em que era anotada a temperatura final e a massa final das carcaças. Para a última pesagem das carcaças foi considerado um tempo de gotejamento de cinco minutos, conforme procedimento padrão da empresa e recomendação do MAPA. Durante este cinco minutos as carcaças permaneciam penduradas em ganchos para só depois serem pesadas.

A velocidade da linha de abate, a temperatura da escaldagem e a temperatura do propilenoglicol no momento de cada coleta eram obtidas de outras planilhas, onde são registradas informações do gerenciamento dos processos do abatedouro. Estes dados são coletados rotineiramente, com o objetivo de detectar desvios dos processos e efetuar as correções necessárias, de modo a garantir o controle e a constância dos resultados de cada etapa do processo.

A necessidade da retirada das carcaças de dentro da água nas passagens de um módulo para outro para conseguir efetuar a pesagem causou alteração dos valores reais, pois houve perda de água e mudança da temperatura durante este trânsito.

Foram realizadas coletas em horários diversos, totalizando 350 conjuntos de informações. Os ajustes das variáveis do processo foram feitos de forma empírica, baseando-se na experiência do operador. Não foi dada nenhuma instrução a ele para proceder de maneira diferenciada durante a coleta dos dados, para que a rotina de operação dos

equipamentos não sofresse nenhum tipo de influência. Os 300 primeiros conjuntos de dados coletados foram utilizados no treinamento, e os 50 restantes na validação.

### 3.4 Arquitetura da rede

Para análise da influência da arquitetura da rede neural sobre a precisão das respostas partiu-se de uma rede prevendo apenas uma das variáveis, com apenas uma camada intermediária. Em seguida foi adicionada a segunda variável resposta, e posteriormente a segunda camada intermediária. Também foi avaliada a resposta de apenas uma variável com duas camadas intermediárias.

Foram testados diferente número de neurônios em cada camada, sendo 3 x 3, 6 x 6, 12 x 12, 3 x 3 x 3 e 6 x 6 x 6. Também foram testados arranjos de números de neurônios conforme recomendado pela literatura, nas configurações 6 x 12 x 9, 6 x 12 x 4 e 4 x 12 x 4.

Inicialmente as redes foram aplicadas considerando todo o sistema de resfriamento (os três módulos de chillers simultaneamente), e posteriormente cada um dos módulos separadamente. Quando avaliados um a um só foram consideradas nas simulações as variáveis relativas aquele módulo (vazão e temperatura da água, borbulhamento, gelo e glicol), além daquelas externas ao resfriamento (peso e temperatura inicial das carcaças, temperatura ambiente e da escaldagem e velocidade da linha e abate).

### 3.5 Treinamento da rede

Em todas as simulações foi utilizada como função de transferência a tangente hiperbólica, como recomendado por MEDEIROS (2006), exceto na camada de saída que utilizava uma função linear.

A função a ser minimizada pelas rotinas de otimização foi a soma dos quadrados dos desvios entre as variáveis previstas e as reais (função erro), na forma da equação abaixo:

$$\varepsilon = \sum_{i=1}^N (y_i - \mu_i)^2 \quad (10)$$

onde

$y_i$  = resposta prevista para o vetor de entrada  $i$

$\mu_i$  = resposta real para o vetor de entrada  $i$

$N$  = número total de vetores avaliados

O critério de convergência foi definido como sendo uma variação menor que  $1 \times 10^{-5}$  da função erro entre uma iteração e outra. Os valores iniciais dos pesos foram estabelecidos



aleatoriamente entre 0 e 0,1. Foram testados valores iniciais maiores e também negativos, que geravam erros de execução nas rotinas computacionais.

### **3.6 Efeitos das variáveis do processo**

As influências das variáveis estudadas sobre o processo foram determinadas utilizando as relações de correlações, conforme descrito no item 2.4.2. Foram determinadas separadamente para a massa e para a temperatura o efeito de cada uma das 25 variáveis.

### **3.7 Modelagem fenomenológica**

O modelo proposto por CARCIOFI e LAURINDO (2007) para descrever a absorção da água pelas carcaças também foi utilizado buscando se prever a massa final das carcaças, descrito pela Eq. (04). Diferente da abordagem utilizando RNA, a aplicação do modelo deve ser feita para cada um dos módulos do sistema de resfriamento. Os parâmetros do modelo  $(K_0, \beta, W_m)$  foram ajustados a partir da minimização da função objetivo, representada pela Eq. (04). Foi empregado o método de otimização SIMPLEX para a estimação dos parâmetros.

A Lei de Newton do Resfriamento, representada pela Eq. (02) também foi aplicada para a temperatura final das carcaças. Novamente, este modelo deve ser aplicado em cada um dos módulos, e não sobre o conjunto deles, como feito para as RNA. O parâmetro do modelo  $k$  foi ajustado a partir da minimização da função objetivo, representada pela Eq. (03). O método de otimização de busca direta *golden search* foi empregado para determinação do parâmetro.

### **3.8 Métodos de otimização**

Foram avaliados três métodos de otimização matemática: Simplex, método de Powell e *Simulated Annealing*. A comparação entre os métodos levou em conta o esforço computacional demandado em cada um deles, o erro absoluto na previsão das respostas e a correlação entre os valores previstos e os experimentais. Quanto maior a correlação e menor o erro mais preciso é o método. Todas as análises foram realizadas em um computador com processador Athlon XP com *clock* de 1,8 GHz e 512 MB de memória RAM.

## **4. RESULTADOS**

Os dados experimentais foram todos normalizados entre 0 e 1 antes de serem utilizados para as simulações, conforme recomendação (Murkherjee & Biswas, citados por FUJITA, 2001). Para cada variável foi encontrado o maior valor, e em seguida todos os demais foram divididos por este. No caso de variáveis negativas dividiu-se pelo menor valor (maior valor em módulo), obtendo-se no final um conjunto de dados positivos. Os valores normalizados de todos os pontos, assim como as respostas reais e previstas, podem ser encontrados na tabela anexa no final do trabalho.

Primeiro foram simuladas redes prevendo uma variável resposta de cada vez (massa da carcaça e temperatura final da carcaça), e depois as duas ao mesmo tempo. Também foram inicialmente testadas redes com apenas uma camada oculta, e depois duas.

Em todos os gráficos que seguem, as informações identificadas com T se referem aos resultados relativos aos dados do treinamento, e V aos dados da validação.

Foram testadas arquiteturas com uma e duas camadas ocultas, e com número de neurônios variando entre 3 e 12 em cada camada. Nas primeiras arquiteturas se utilizou o mesmo número de neurônios em cada camada (exceto na de saída), e na seqüência se testaram os arranjos recomendados por MEDEIROS (2006). Em todos os casos o número de neurônios na camada de saída é igual ao número de respostas previstas, uma ou duas.

Dos métodos de otimização testados, o que se mostrou mais rápido e confiável foi o Simplex. Todos os resultados a seguir foram determinados utilizando-se este método, exceto quando citado de outra forma. Em todos os casos a tolerância empregada no ajuste dos parâmetros foi de  $1 \times 10^{-5}$ .

Um ponto importante a ser lembrado é que os resultados obtidos pelas redes neurais só devem ser considerados dentro dos intervalos observados na coleta de dados para cada variável. Extrapolações para valores fora deste intervalo devem ser feitas com cautela, pois não existe garantia nenhuma de que estas respostas tenham coerência com a realidade.

### **4.1 Previsão somente da temperatura**

Foram testadas diferentes arquiteturas de rede (conforme descrito no item 3.4) para prever a temperatura de saída das carcaças, e consideradas todas as 25 variáveis de entrada. Os erros obtidos no ajuste e na validação da rede são apresentados na Figura 14. Observa-se que as diferentes arquiteturas influenciam muito pouco no erro durante o treinamento da rede,

porém há grande diferença na validação. A melhor das arquiteturas testadas é a 6 x 6 x 6, porém o erro encontrado na validação de todas elas é demasiadamente alto. Para a correlação se tem um comportamento parecido com o do erro, com a rede 6 x 6 x 6 com o melhor resultado, mas ainda com uma baixa correlação na validação. A Figura 15 mostra a correlação para cada uma das arquiteturas avaliadas, calculada pela Eq. (06). O coeficiente da correlação ficou muito distante da unidade o que indica que o modelo não foi eficaz para representar os dados experimentais da temperatura da carcaça do frango.

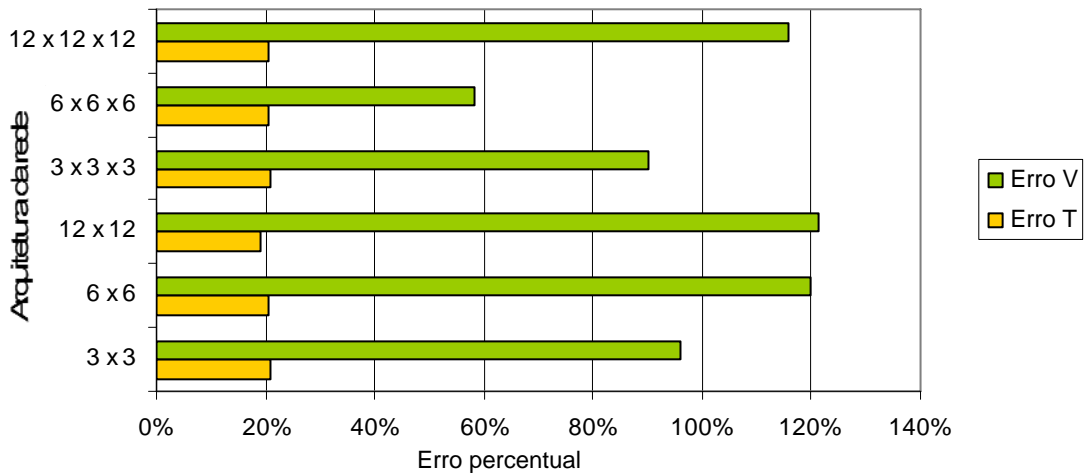


Figura 14 – Erro no treinamento e validação da rede, prevendo apenas temperatura, para diferentes arquiteturas.




Figura 15 – Correlação no treinamento e validação da rede, prevendo apenas temperatura, para diferentes arquiteturas.

As Figuras 16 e 17 demonstram o crescimento do esforço computacional com o número de pesos envolvidos no treinamento. O comportamento observado é linear.




Figura 16 – Número de iterações no treinamento da rede, prevendo apenas temperatura, para diferentes arquiteturas.




Figura 17 – Correlação entre o número de pesos da rede e o número de iterações até convergência.

#### 4.2 Previsão somente da massa

Foram testadas diferentes arquiteturas de rede (conforme descrito no item 3.4) para prever a massa das carcaças na saída do último chiller, e consideradas todas as 25 variáveis de entrada. Os erros obtidos no ajuste e na validação da rede são apresentados na Figura 18 e as correlações na Figura 19. Observa-se uma influência muito pequena da arquitetura da rede com o erro na previsão da massa final das carcaças, principalmente no treinamento. Na validação se observa alguma influência, mas todas as arquiteturas com patamares muito

baixos, demonstrando uma precisão muito boa. O melhor resultado novamente foi obtido na arquitetura 6 x 6 x 6. A análise da correlação leva às mesmas conclusões da interpretação do erro. Novamente a arquitetura 6 x 6 x 6 mostra ser a melhor, porém há pouca diferença entre os modelos. O coeficiente da correlação ficou muito próximo da unidade o que indica que o modelo conseguiu representar satisfatoriamente os dados experimentais da massa da carcaça do frango.

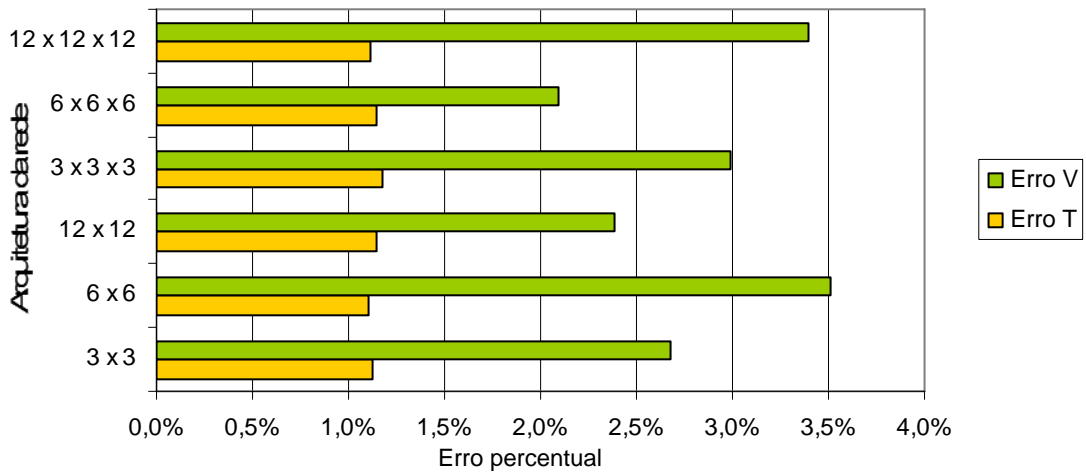


Figura 18 – Erro no treinamento e validação da rede, prevendo apenas a massa final, para diferentes arquiteturas.

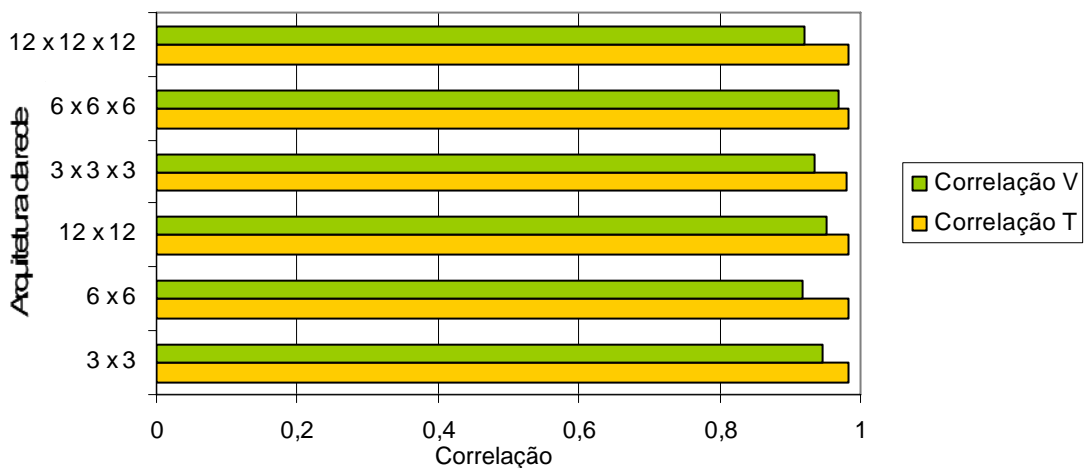


Figura 19 – Correlação no treinamento e validação da rede, prevendo apenas a massa final, para diferentes arquiteturas.

As Figuras 20 e 21 demonstram o crescimento do esforço computacional com o número de pesos envolvidos no treinamento. Novamente o comportamento observado é

linear, porém com uma convergência (ou taxa de aprendizagem) muito mais rápida que na previsão apenas da temperatura.




Figura 20 – Número de iterações no treinamento, prevendo apenas a massa final, para diferentes arquiteturas.

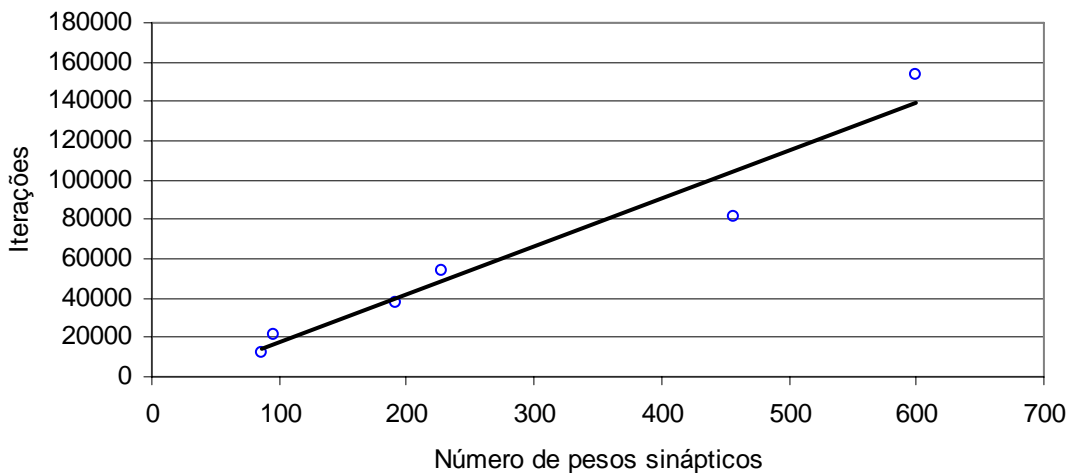


Figura 21 – Correlação entre o número de pesos da rede e o número de iterações até convergência.

### 4.3 Previsão conjunta da massa e da temperatura

Foram testadas diferentes arquiteturas de rede (conforme descrito no item 3.4) para prever simultaneamente a massa e a temperatura das carcaças na saída do último chiller, e consideradas todas as 25 variáveis de entrada. Os erros obtidos no ajuste e na validação da

rede são apresentados na Figura 22. Os resultados obtidos para a temperatura, neste caso, a melhor arquitetura é a uma camada intermediária com 12 neurônios de entrada e 12 neurônios na camada intermediária. Porém, na análise considerando as duas variáveis de saída (massa e temperatura), a rede com arquitetura a 3 x 3 parece ser mais apropriada, pois os ganhos na temperatura não são muitos significativos. A mesma conclusão sobre o erro pode ser usada para a correlação. A rede mais simples treinada parece ser a melhor para o conjunto das variáveis, como pode ser observado nas Figuras 22 e 23. Entretanto, deve-se destacar que a rede não conseguiu representar a temperatura da carcaça.

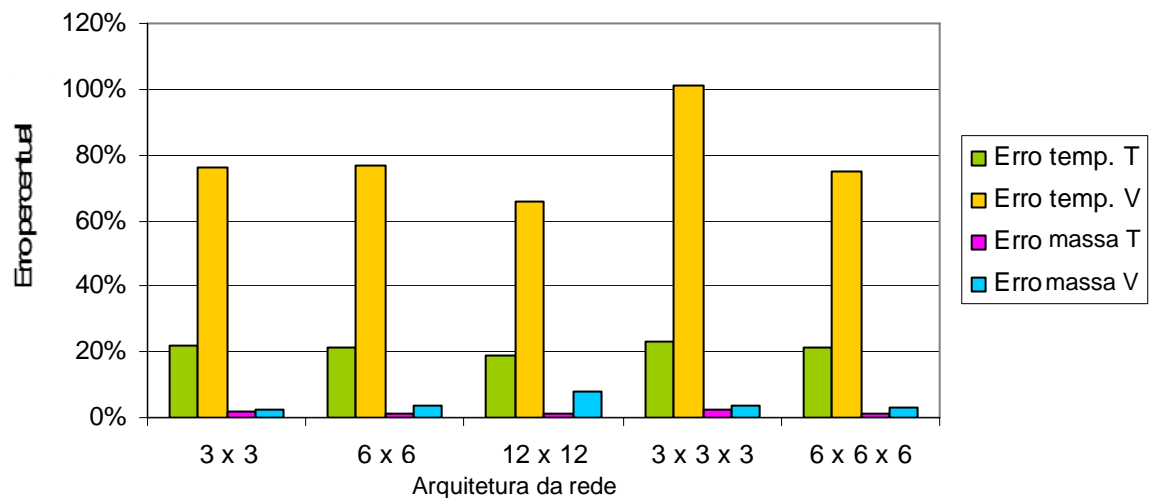


Figura 22 – Erro no treinamento e validação da rede, prevendo temperatura a massa ao mesmo tempo, para diferentes arquiteturas.

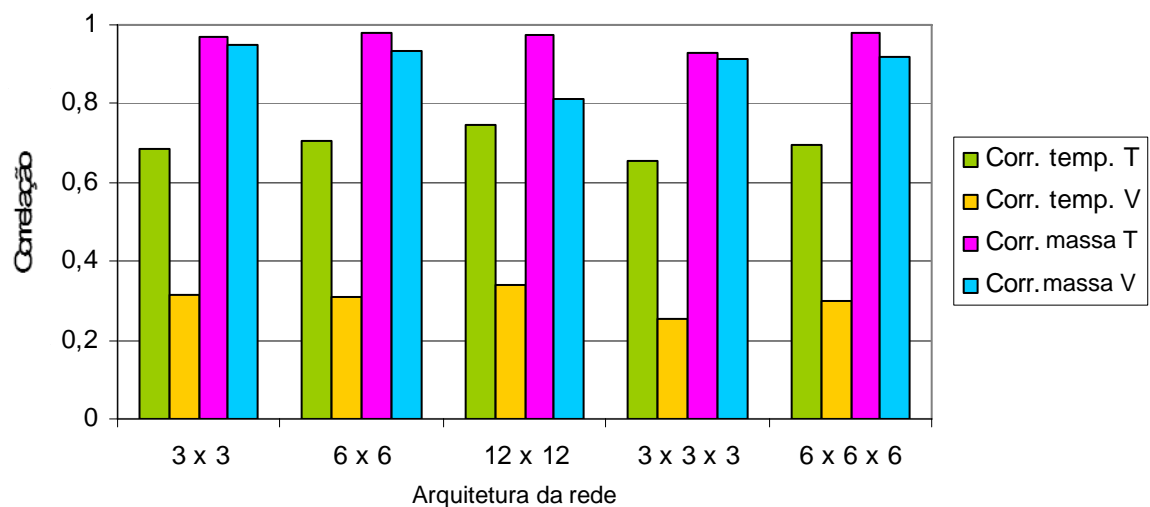


Figura 23 – Correlação no treinamento e validação da rede, prevendo temperatura e massa ao mesmo tempo, para diferentes arquiteturas.

O esforço computacional para a rede prevendo as duas variáveis também segue o comportamento linear. Há uma ressalva da arquitetura 12 x 12 x 12, pois a rotina de otimização extrapolou seis milhões de iterações sem convergência. A dificuldade na aprendizagem é equivalente às dificuldades das duas redes com uma saída somadas. As Figuras 24 e 25 representam estas conclusões.




Figura 24 – Número de iterações no treinamento da rede, prevendo temperatura e massa ao mesmo tempo, para diferentes arquiteturas.

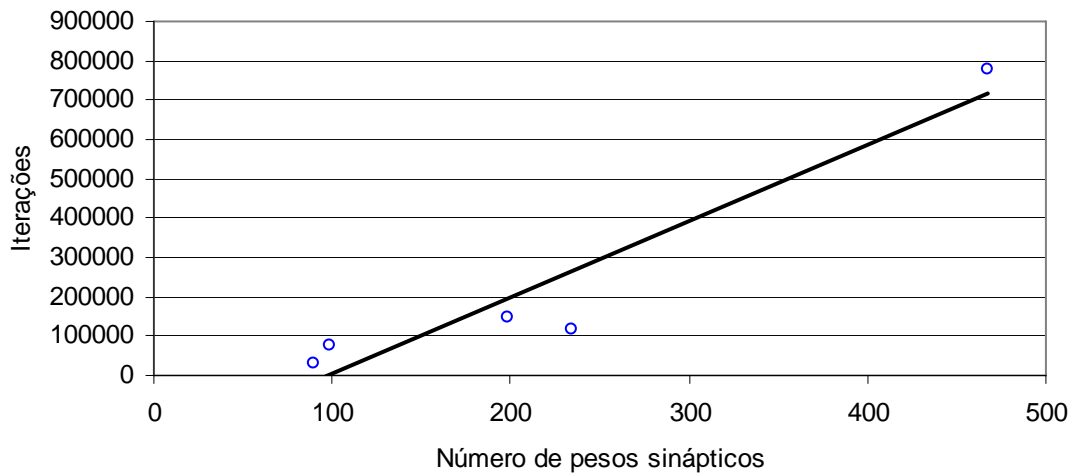


Figura 25 – Correlação entre o número de pesos da rede e o número de iterações até convergência.



#### 4.4 Uso de redes com arquiteturas alternativas

Seguindo o recomendado por MEDEIROS (2006) foram testadas outras arquiteturas de redes com duas camadas ocultas e como variáveis resposta da rede a temperatura e a massa das carcaças.

As Figuras 26 e 27 mostram que a rede 4 x 12 x 4 apresentou os melhores resultados, tanto para o erro como para a correlação, valores próximos ou até um pouco melhores que da rede 3 x 3 recomendada na análise anterior.

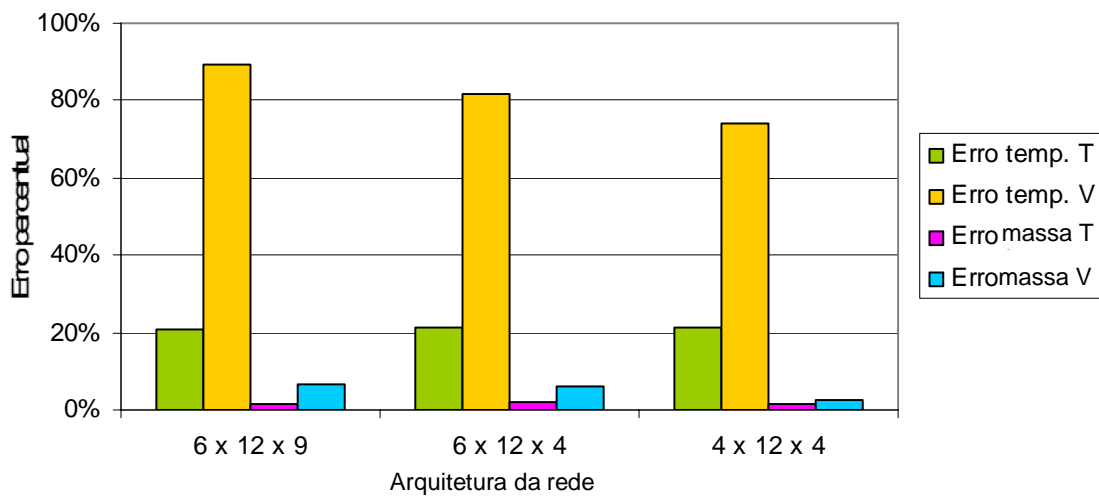


Figura 26 – Erro no treinamento e validação da rede, prevendo temperatura e massa ao mesmo tempo, para arquiteturas alternativas.

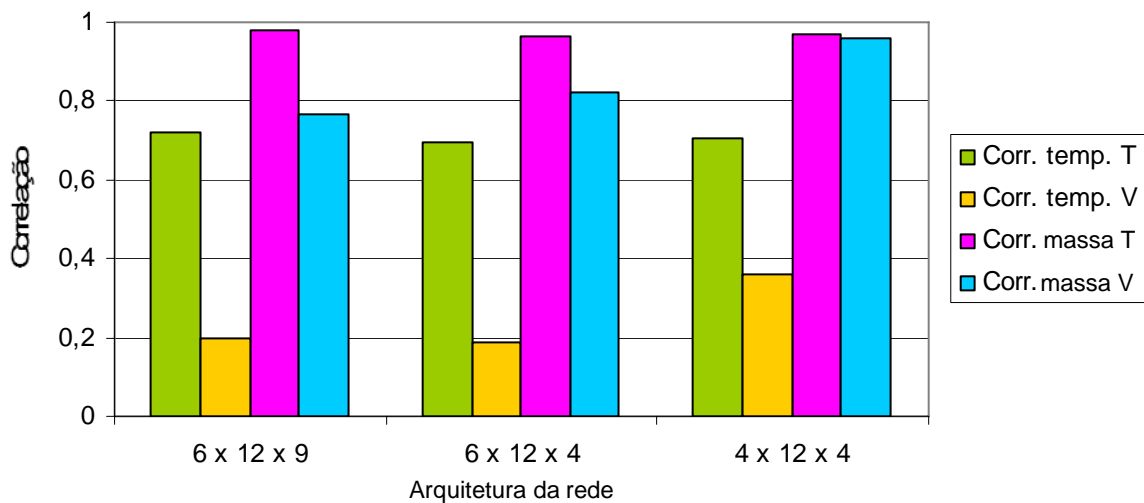


Figura 27 – Correlação no treinamento e validação da rede, prevendo temperatura e massa ao mesmo tempo, para arquiteturas alternativas.

As Figuras 28 e 29 mostram que o esforço computacional nas redes com duas camadas ocultas com a arquitetura recomendada por MEDEIROS (2006) apresentam a mesma velocidade de aprendizagem que as arquiteturas convencionais.




Figura 28 – Número de iterações no treinamento da rede, prevendo temperatura e massa ao mesmo tempo, para arquiteturas alternativas.




Figura 29 – Correlação entre o número de pesos da rede e o número de iterações até convergência.

A Figura 30 mostra que a rede representa a previsão do comportamento observado para temperatura, porém com uma grande dispersão mesmo no treinamento. Já a Figura 31, com o comportamento na validação, não deixa dúvida de a rede não é capaz de prever esta resposta com segurança.




Figura 30 – Gráfico de correlação entre a temperatura real normalizada e a temperatura prevista normalizada no treinamento da rede 4 x 12 x 4 prevendo também a massa.

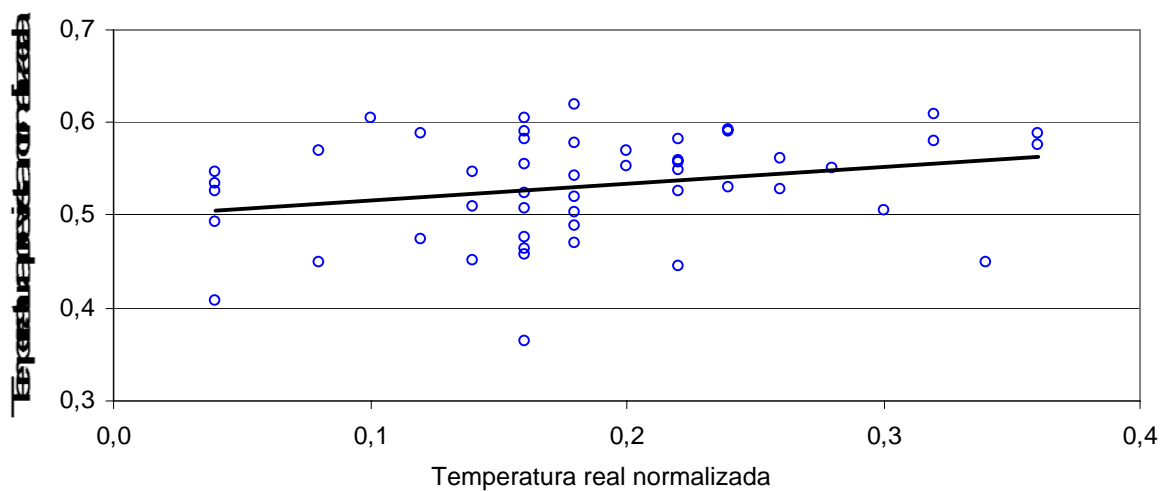


Figura 31 – Gráfico de correlação entre a temperatura real normalizada e a temperatura prevista normalizada na validação da rede 4 x 12 x 4 prevendo também a massa.

Diferente da temperatura, os resultados para a previsão da massa foram excelentes, tanto no treinamento como na validação, como pode ser observado nas Figuras 32 e 33.




Figura 32 – Gráfico de correlação entre a massa real normalizada e a massa prevista normalizada no treinamento da rede 4 x 12 x 4 prevendo também a temperatura.

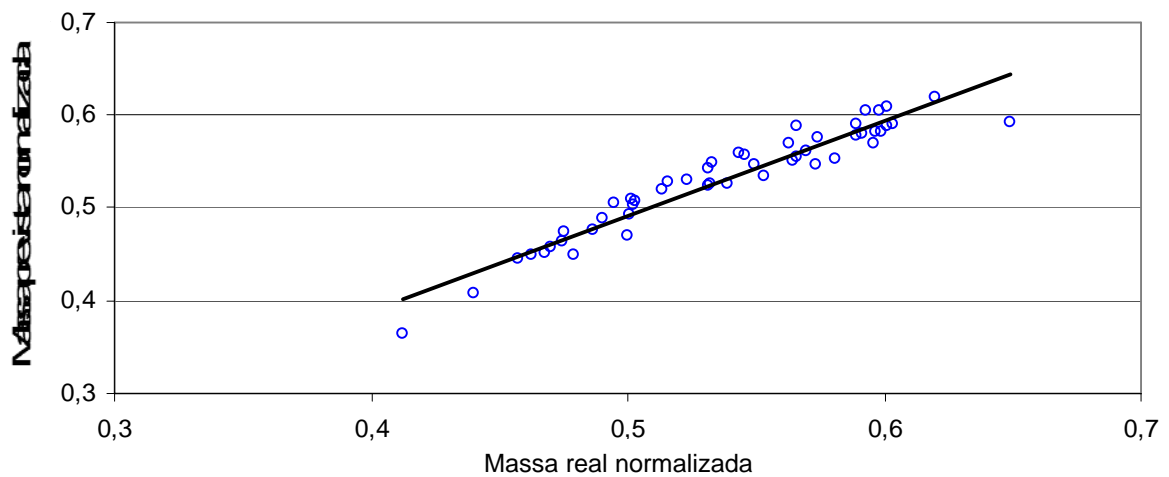


Figura 33 – Gráfico de correlação entre a massa real normalizada e a massa prevista normalizada na validação da rede 4 x 12 x 4 prevendo também a temperatura.

#### 4.5 Modelagem do processo de resfriamento separado de cada um dos chillers

Foram implementadas três redes neurais para prever em cada um dos módulos do sistema de resfriamento ao invés de uma única rede para todo o sistema de resfriamento que é composto por três tanques de imersão. As variáveis de resposta da rede foram a temperatura e a massa na saída de cada um dos chillers. Os resultados obtidos para cada um dos chillers são apresentados nas Figuras 34 e 35. Observa-se que no final do primeiro módulo, tanto no

treinamento quanto na validação, a temperatura e a massa foram previstas com boa precisão. No final do segundo módulo há um aumento do erro nas duas previsões, mas com uma recuperação apenas do resultado da massa no final do terceiro módulo. Há então uma contaminação dos dados no segundo módulo que influencia de maneira irrecuperável a determinação da temperatura. A provável origem desta contaminação é a alteração impingida nas variáveis no próprio procedimento de coleta, como descrito no item 3.3.




Figura 34 – Erro no treinamento e validação da rede, prevendo temperatura e massa ao mesmo tempo, no final de cada um dos chillers, para a arquitetura 4 x 12 x 4.

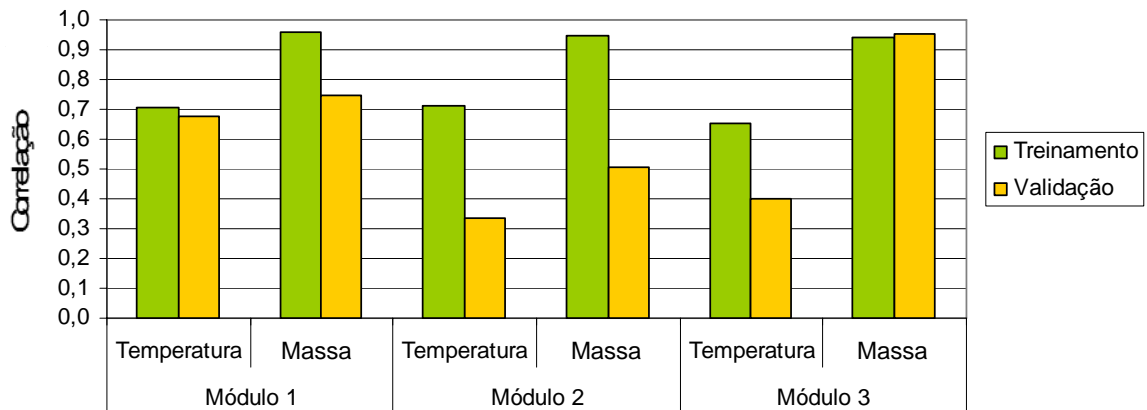


Figura 35 – Correlação no treinamento e validação da rede, prevendo temperatura e massa ao mesmo tempo, no final de cada um dos chillers, para a arquitetura 4 x 12 x 4.

#### 4.6 Análise da influência das variáveis

A análise de significância das variáveis de entrada sobre as respostas das RNA foi realizada empregando o método recomendado por FUJITA (2001) e apresentado na seção 4.2, que se baseia no cálculo do coeficiente de correlação  $R_j$  obtido pela eliminação da variável  $j$  de entrada da rede, em relação ao índice de correlação da rede treinada com todas as variáveis de entrada. Todos os fatores com valor do coeficiente de correlação inferior a 1% foram considerados como não influentes no processo.

De acordo com a Figura 36, a temperatura final da carcaça é influenciada por um grande número de variáveis, sendo elas:

$X_{10}$ : massa inicial da carcaça;

$X_2$ : velocidade do abate;

$X_{24}$ : temperatura do glicol no chiller 2;

$X_{25}$ : vazão de renovação no chiller 2;

$X_{20}$ : temperatura da água no início do chiller 3;

$X_5$ : temperatura da água no início do pré-chiller;

$X_{21}$ : temperatura da água no final do chiller 2;

$X_{11}$ : temperatura inicial da carcaça;

$X_{13}$ : temperatura da água no início do chiller 2;

$X_{23}$ : quantidade de gelo no chiller 2;

$X_{19}$ : tempo de residência no chiller 2;

$X_7$ : intensidade do borbulhamento no pré-chiller;

$X_1$ : temperatura da escaldagem;

$X_{17}$ : temperatura do glicol no chiller 1;

$X_3$ : temperatura ambiente;

$X_{14}$ : temperatura da água no final do chiller 1.

Somados os respectivos índices, a temperatura da água encontrada pela carcaça se torna o conjunto de fatores mais importante ( $X_{20}+X_5+X_{21}+X_{13}+X_{14}$ ), responsável por 8,86% dos efeitos observados. Em seguida está o volume do abate, caracterizado pela velocidade e a massa das carcaças ( $X_{10}+X_2$ ), que respondem por 7,99% do total. O terceiro fator é a energia disponível para manter a temperatura da água baixa, com 7,43% de influência, representado pela vazão de renovação, temperatura do glicol e massa de gelo adicionada ( $X_{24}+X_{25}+X_{23}+X_{17}$ ). A quantidade de energia trazida pela carcaça fica em quarto lugar, com a temperatura inicial da carcaça e a temperatura da escaldagem. Somente após estes fatores

aparece o tempo de retenção com 1,70%, a intensidade do borbulhamento com 1,57%, e a temperatura ambiente com 1,29%.




Figura 36 – Influência de cada uma das variáveis na previsão da temperatura das carcaças para a rede 4 x 12 x 4 prevendo também a massa.

Para a previsão da massa apenas três fatores se destacaram, sendo eles a massa inicial das carcaças com 31,93%, a temperatura da água no início do pré-chiller com 2,62%, e o borbulhamento do chiller 1 com 2,45%, conforme mostrado na Figura 37.




Figura 37 – Influência de cada uma das variáveis na previsão da massa das carcaças para a rede 4 x 12 x 4 prevendo também a temperatura.

#### 4.7 Análise da rotinas de otimização

Foram avaliados três métodos de otimização para a busca dos pesos da RN, sendo eles o Simplex, método de Powell e *Simulated Annealing*. Como descrito anteriormente cada um deles utiliza um caminho para encontrar os valores ideais, com maior ou menor esforço computacional em cada alternativa. Desta forma não é possível comparar estes esforços baseando-se apenas no número de iterações necessários para atingir um determinado erro. Em tempo de processamento o método mais rápido foi o Simplex, seguido do método de Powell e depois do *Simulated Annealing*. Este tempo foi avaliado em redes com arquitetura 6 x 6, de apenas uma camada intermediária, prevendo massa e temperatura ao mesmo tempo. A análise foi posteriormente repetida para a arquitetura 4 x 12 x 4, escolhida conforme análise feita no item 4.4, sendo que os comportamento encontrados foram os mesmos. O simplex levou menos da metade do tempo utilizado pelos outros métodos para atingir o mesmo erro.

Em otimizações de redes com arquiteturas mais complexas, com um número maior de neurônios e de pesos, se observou muita instabilidade do método de Powell, além de taxas de convergência muito lentas. Já o *simulated annealing* se mostrou confiável, porém também com convergência muito lenta. As alterações possíveis nos processos de otimização de cada método não foram significativas para aumentar a taxa de convergência ou diminuir o erro final.

Para a rede 4 x 12 x 4, a figura 38 mostra que o simplex foi um pouco melhor que a *simulated annealing* (SA) tanto no treinamento quanto na validação da massa final das carcaças. Para a temperatura os resultados do treinamento foram praticamente idênticos, com uma pequena vantagem na validação, mas ainda mostrando um erro extremamente alto. O método de Powell não foi levado em conta, pois apresentou erros em alguns pontos maiores que 1000%.






Figura 38 – Erro no treinamento e validação da rede prevendo temperatura e massa ao mesmo tempo para a arquitetura 4 x 12 x 4 e para as diferentes rotinas de otimização.

Já a Figura 39 faz uma análise da correlação entre os valores reais e os estimados por cada um dos métodos. Nota-se novamente uma vantagem do simplex sobre os demais, seguido da SA e depois do método de Powell. Na validação da temperatura SA leva pequena vantagem sobre o simplex, mas ambos com correlação muito baixa.





Figura 39 – Correlação no treinamento e validação da rede prevendo temperatura e massa ao mesmo tempo para a arquitetura 4 x 12 x 4 e para as diferentes rotinas de otimização.

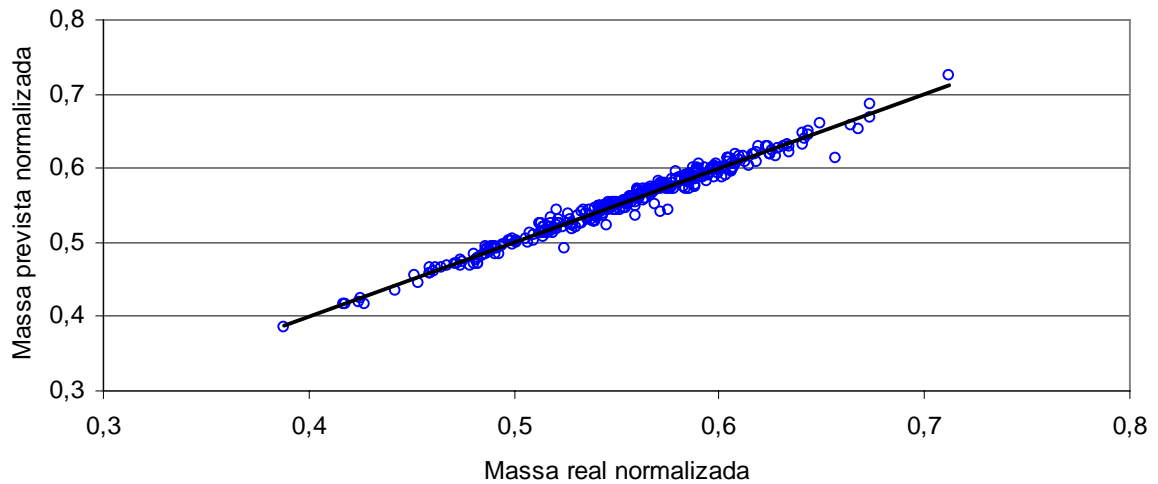
#### 4.8 Aplicação do modelo fenomenológico para previsão da massa

O modelo de CARCIOFI e LAURINDO (2007) foi aplicado para cada um dos módulos do sistema de resfriamento, com o objetivo de comparar os resultados com os previstos pela rede neural. Foram otimizados os parâmetros  $K_0$ ,  $\beta$  e  $W_m$  também utilizando Simplex, de maneira semelhante a utilizada para os pesos das redes neurais. Os resultados encontrados foram excelentes, melhores até do que os descritos no trabalho dos autores. Os erros encontrados foram de 0,69%, 1,00% e 1,53% para o pré-chiller, chiller 1 e chiller 2, respectivamente. As correlações foram de 0,9944, 0,9895 e 0,9770 também na mesma ordem. As Figuras 40, 41 e 42 mostram as correlações entre as massas previstas e reais.




$K_0 = 35,14 \text{ min}^{-1}$ ,  $\beta = -221,58 \text{ [kg água/kg carcaça]}$  e  $W_m = 309,68 \text{ [kg água/kg carcaça]}$

Figura 40 – Gráfico de correlação entre a massa real normalizada e a massa prevista normalizada na aplicação do modelo de CARCIOFI & LAURINDO para o pré-chiller.



$K_0 = 24,77 \text{ min}^{-1}$ ,  $\beta = -151,99 \text{ [kg \u00e1gua/kg carca\u00e7a]}$  e  $W_m = 214,62 \text{ [kg \u00e1gua/kg carca\u00e7a]}$

Figura 41 – Gr\u00e1fico de correla\u00e7\u00e3o entre a massa real normalizada e a massa prevista normalizada na aplica\u00e7\u00e3o do modelo de CARCIOFI & LAURINDO para o chiller 1.




$K_0 = 24,38 \text{ min}^{-1}$ ,  $\beta = -309,75 \text{ [kg \u00e1gua/kg carca\u00e7a]}$  e  $W_m = 455,40 \text{ [kg \u00e1gua/kg carca\u00e7a]}$

Figura 42 – Gr\u00e1fico de correla\u00e7\u00e3o entre a massa real normalizada e a massa prevista normalizada na aplica\u00e7\u00e3o do modelo de CARCIOFI & LAURINDO para o chiller 2.

#### 4.9 Aplica\u00e7\u00e3o da Lei de Newton do Resfriamento para previs\u00e3o da temperatura


A Lei de Newton do Resfriamento foi aplicada em um dos m\u00f3dulos do sistema de resfriamento com o objetivo de comparar os resultados com os previstos pela rede neural. Foi otimizados o par\u00e2metro  $k$  tamb\u00e9m utilizando Simplex, de maneira semelhante a utilizada para

os pesos das redes neurais. Foi considerada como temperatura ambiente de cada módulo a média entre a temperatura da água na entrada e na saída dos chillers. Os resultados encontrados foram piores até do que os previstos pela RNA. No primeiro módulo ainda houve certa coerência na previsão, como mostrado na Figura 43, mas nos módulos seguintes os valores encontrados estão completamente fora do esperado. As Figuras 44 e 45 evidenciam esta conclusão.



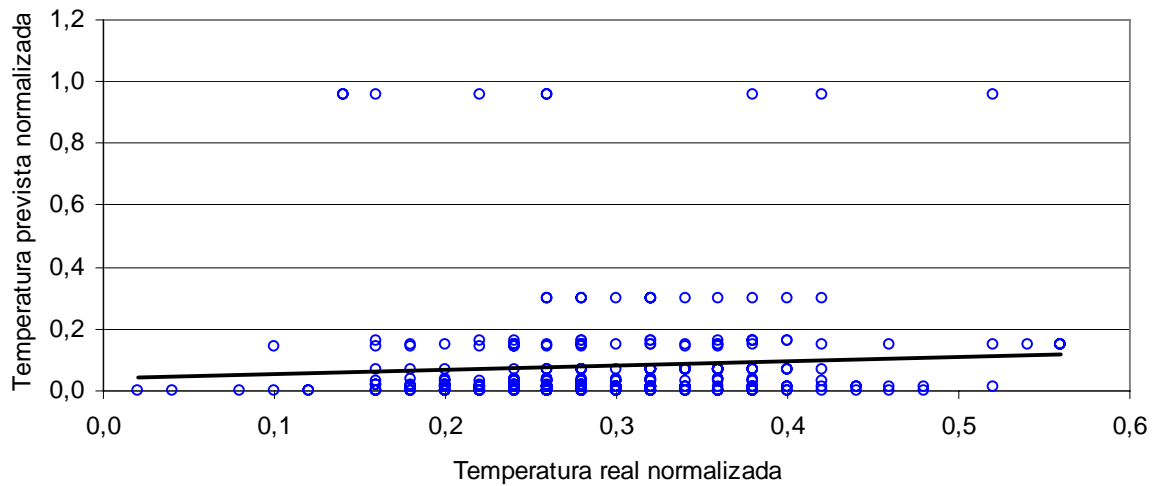
$$k = -0,6178 \text{ min}^{-1}$$

Figura 43 – Gráfico de correlação entre a temperatura real normalizada e a temperatura prevista normalizada na aplicação da Lei do Resfriamento de Newton para o pré-chiller.



$$k = 0,2443 \text{ min}^{-1}$$

Figura 44 – Gráfico de correlação entre a temperatura real normalizada e a temperatura prevista normalizada na aplicação da Lei do Resfriamento de Newton para o chiller 1.



$$k = 0,2000 \text{ min}^{-1}$$

Figura 45 – Gráfico de correlação entre a temperatura real normalizada e a temperatura prevista normalizada na aplicação da Lei do Resfriamento de Newton para o chiller 2.

#### 4.10 Desenvolvimento de planilha para previsão da absorção

A partir dos resultados obtidos no treinamento da rede com estrutura 4 x 12 x 4 considerando como variável de saída apenas a massa da carcaça da massa final das carcaças foi desenvolvida um planilha de cálculo de maneira a simular qual seria a resposta para um dado conjunto de parâmetros. Esta planilha poderá ser utilizada pelo operador da fábrica responsável pelo sistema de resfriamento para auxiliar na sua tomada de decisões. A Figura 46 mostra a interface desta planilha.

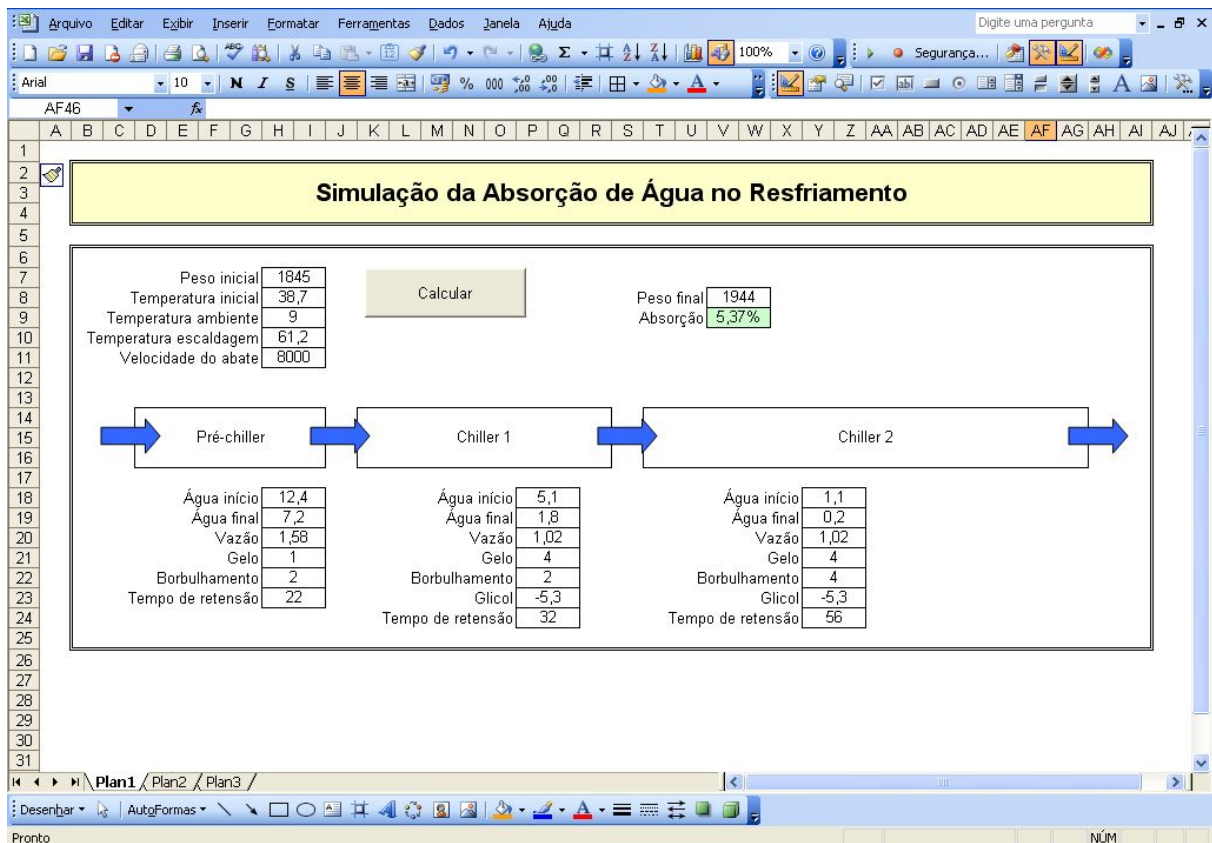


Figura 46 – Tela de interface com o operador da planilha de cálculo para previsão da massa final das carcaças.

Pretende-se utilizar a planilha na linha estudada, verificando-se a praticidade e funcionalidade. Em seguida será ampliada para as demais linhas. A planilha faz automaticamente a normalização dos dados de entrada e aplica na rede neural juntamente com os pesos que tem gravados em sua memória. Caso a massa final esteja próxima do limite da legislação (entre 7 e 8%) a célula “Absorção” é pintada de laranja. Se estiver distante do máximo é pintada de verde (abaixo de 7%), e se estiver acima do máximo (mais que 8%) de vermelho.

Outra aplicação pretendida para esta planilha é reduzir os custos de operação do sistema de resfriamento, e também o consumo de água.

## 5. CONCLUSÃO

Neste trabalho foi investigado o emprego das redes neurais para descrever o processo de resfriamento de frango em chillers de imersão, na qual foram consideradas como variáveis de saída a temperatura e a massa das carcaças. Também foram testados o modelo empírico proposto por CARCIOFI e LAURINDO (2007) para descrever a absorção de água e o modelo de resfriamento de Newton para a previsão de temperatura das carcaças. Os principais resultados obtidos neste trabalho foram os seguintes:

- As redes neurais artificiais mostraram que funcionam muito bem para previsão da absorção de água pelas carcaças de frango no processo de resfriamento por imersão, mesmo quando modelando todo o sistema ao mesmo tempo, grande vantagem sobre o modelo fenomenológico.
- O modelo proposto por CARCIOFI e LAURINDO (2007) também se mostrou eficiente para prever a absorção da água pelas carcaças de frango, entretanto, a utilização de redes neurais é mais válida porque leva em conta as 25 variáveis de entrada..
- As redes neurais não foram eficientes para prever a temperatura final das carcaças, assim como a abordagem fenomenológica pela Lei de Newton do Resfriamento.
- Atribui-se ao procedimento de coleta adotado na passagem das carcaças de um módulo para outro o grande erro encontrado na previsão da temperatura.
- A arquitetura da rede influenciou pouco na precisão dos resultados. O número de camadas e de neurônios em cada uma delas praticamente não altera o resultado final. As arquiteturas alternativas também não apresentaram vantagens significativas, uma vez que mesmo as convencionais mais simples forneceram boas previsões.
- A previsão conjunta da absorção e da temperatura foi um pouco pior para a temperatura do que na previsão independente, mas quase sem significância para a absorção, mostrando que a rede consegue ser precisa em uma das saídas mesmo quando uma das outras apresenta algum problema de aprendizagem.
- As variáveis mais importantes encontradas para a absorção foram o peso inicial da carcaça, depois a temperatura da água no primeiro estágio, seguida do borbulhamento do segundo estágio. O tempo de resfriamento, parâmetro do modelo fenomenológico, não apareceu entre os mais influentes. Para a temperatura o erro foi muito grande para se considerar os resultados encontrados como sendo conclusivos.
- O método de otimização Simplex se mostrou mais vantajoso sobre os demais, para os tipos de arranjo testados. Mostrou-se mais estável e também mais rápido, além de aproximar os

valores procurados com uma previsão tão boa quanto, ou até melhor, que as outras rotinas testadas. Em todos os casos o esforço computacional do simplex cresce linearmente com a quantidade de pesos sinápticos.

- O desenvolvimento da planilha de cálculo baseada no resultado da modelagem por redes neurais demonstrou ser de grande utilidade e aplicabilidade, pois auxilia na decisão das correções a serem feitas no processo produtivo.
- Uma sugestão de trabalho futuro é refazer a coleta dos dados, desconsiderando os valores intermediários, de forma a não embutir erros nos valores finais da temperatura. Com estes dados deve-se treinar as redes novamente e verificar o erro nas previsões.
- Outra sugestão é analisar a influência de cada uma das variáveis pelo método da análise dos componentes principais.
- Um desenvolvimento importante a ser feito no resfriamento de carcaças é a otimização energética, e a ferramenta desenvolvida neste trabalho pode ajudar e servir de base para esta aplicação.



## 6. BIBLIOGRAFIA

- ALLEN, V. M. *et al.* **Hygiene aspects of modern poultry chilling**. R. *International Journal of Food Microbiology*, p 1-10, 2000.
- ANTONELLI, G. C. **Controle de Processos com Redes Neurais Inversas**. Maringá: Departamento de Engenharia Química, Universidade Estadual de Maringá, 1998. 110 p. Dissertação (Mestrado).
- BRAGA, A. P.; CARVALHO, A. P. L.; LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: LTC – Livros Técnicos e Científicos, 2000. 262 p.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento - MAPA. **Regulamento Técnico da Inspeção Tecnológica e Higiênico-Sanitária de Carne de Aves**. Portaria n. 210, de 10 de novembro de 1998.
- CARCIOFI, B. A. M.; LAURINDO, J. B. **Water uptake by poultry carcasses during cooling by water immersion**. R. *Chemical Engineering and Processing*, n. 46, p. 444-450, 2007.
- COELHO, L. S. **Fundamentos, potencialidades e aplicações de algoritmos evolutivos**. São Carlos: SBMAC, 2003. 111 p.
- CORAZZA, F. C. **Estimação de Estado e Controle Ótimo em um Secador Industrial de Gelatina – Análise de Viabilidade Técnica**. Maringá: Departamento de Engenharia Química, Universidade Estadual de Maringá, 2004. 139 p. Tese (Doutorado).
- DYER, Jerry. **Comunicação pessoal ao autor**, em 30 de maio de 2007.
- ELIAS, M. **Redes Neurais Artificiais**. Disponível em [www.geocities.com/capecanaveral/runway/4303/index.html](http://www.geocities.com/capecanaveral/runway/4303/index.html). Acesso em 14 de outubro de 2007.

- FRANCISCO, C. O. **Modelagem e simulação de um secador industrial de gelatina através de redes neurais artificiais**. Campinas: Faculdade de Engenharia Química, Universidade Estadual de Campinas, 2000. 112 p. Dissertação (Mestrado).
- FUJITA, E. G. L. **Modelagem de forno para a produção de cimento através da aplicação de técnicas de redes neurais**. Campinas: Faculdade de Engenharia Química, Universidade Estadual de Campinas, 2001. 100 p. Dissertação (Mestrado).
- GALKIN, I. **Crash Introduction to Artificial Neural Networks**. Disponível em <<http://ulcar.uml.edu/~iag/CS/Intro-to-ANN.html>>. Acesso em 14 de outubro de 2007.
- GOÑI, S. M. *et al.* **Prediction of foods freezing and thawing times: artificial neural networks and genetic algorithm approach**. *R. Journal of Food Engineering*, no.84, p 164-178, 2008.
- JAMES, C. *et al.* **The primary chilling of poultry carcasses – a review**. *R. International Journal of Refrigeration*, p 1-17, 2006.
- KOVÁCS, Z. L. **Redes neurais artificiais: fundamentos e aplicações**. São Paulo: Editora Livraria de Física, 2002. 174 p.
- LINCO. **Catálogo de Equipamentos para Abate e Processamento de Frangos**. Dinamarca, 2004.
- MEDEIROS. F. T. P. **Desenvolvimento de um modelo de predição de condições operacionais de altos-fornos siderúrgicos com base em redes neurais artificiais**. Campinas: Faculdade de Engenharia Química, Universidade Estadual de Campinas, 2006. 134 p. Tese (Doutorado).
- MITTAL, G. S.; ZHANG, J. **Prediction of food thermal process evaluation parameters using neural networks**. *R. International Journal of Food Microbiology*, no.79, p 153-159, 2002.

- MITTAL, G. S.; ZHANG, J. **Prediction of freezing time for food products using a neural network**. *R. Food Research International*, no.33, p 557-562, 2000.
- NEVES FILHO, L. C. **Estudo de algumas variáveis no resfriamento contínuo por imersão de frango**. Campinas: Faculdade de Engenharia de Alimentos e Agrícola, Universidade Estadual de Campinas, 1978. 164 p. Tese (Mestrado).
- PRESS, W. H. *et al.* **Numerical Recipes in Fortran 77: the art of scientific computing**. Cambridge: Press Syndicate of the University of Cambridge, 1992. 973 p.
- QIAO, J. *et al.* **Predicting mechanical properties of fried chicken nuggets using image processing and neural network techniques**. *R. Journal of Food Engineering*, no.79, p 1065-1070, 2007.
- SAVELL, J. W.; MUELLER, S. L; BAIRD, B. E. **The chilling of carcasses**. *R. Meat Science*, p 1-11, 2004.
- SILVA, E. C. N. **Otimização aplicada ao projeto em engenharia mecânica**. [S.n.t.]
- TAFNER, M. **Redes Neurais Artificiais: Aprendizado e Plasticidade**. Disponível em <<http://www.cerebromente.org.br/n05/tecnologia/plasticidade2.html>>. Acesso em 06 de janeiro de 2008.
- TATIBANA, C. Y.; KAETSU, D. Y. **Uma Introdução às Redes Neurais**. Disponível em <<http://www.din.uem.br/ia/neurais>>. Acesso em 14 de outubro de 2007.
- TERUEL, B.; CORTEZ, L. A.; NEVES FILHO, L. **Estudo comparativo do resfriamento de laranja valência com ar forçado e com água**. *R. Ciência e Tecnologia de Alimentos*, vol.23, no.2, p 174-178, 2003.
- TERUEL, B. *et al.* **Estudo teórico do resfriamento com ar forçado de frutas de geometrias diferentes**. *R. Ciência e Tecnologia de Alimentos*, vol.21, no.2, p 228-235, 2001.

WANG, L.; SUN, D. **Evaluation of performance of slow air, air blast and water immersion cooling methods in the cooked meat industry by the finite element method.** *R. Journal of Food Engineering*, p 1-12, 2001.

## **ANEXOS**