



**LUIZ HENRIQUE FALEIRO SIDNEY**

**UTILIZAÇÃO DE REDES NEURAIIS  
ARTIFICIAIS PARA A APROXIMAÇÃO DE  
GANHOS DE PESO DE FRANGOS DE CORTE**

**LAVRAS - MG  
2011**

**LUIZ HENRIQUE FALEIRO SIDNEY**

**UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS PARA A  
APROXIMAÇÃO DE GANHOS DE PESO DE FRANGOS DE CORTE**

Monografia apresentada ao colegiado do Curso de Sistemas de Informação, como uma das exigências para a obtenção do título de Bacharel em Sistemas de Informação.

Orientador:

Dr. Tadayuki Yanagi Junior

Co-orientadores:

M.Sc. Patrícia Ferreira Ponciano

Dr. Wilian Soares Lacerda

**LAVRAS - MG  
2011**

**LUIZ HENRIQUE FALEIRO SIDNEY**

**UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA A  
APROXIMAÇÃO DE GANHOS DE PESO DE FRANGOS DE CORTE**

Monografia apresentada ao colegiado do Curso  
de Sistemas de Informação, como uma das  
exigências para a obtenção do título de Bacharel  
em Sistemas de Informação.

APROVADA em 09 de dezembro de 2011

D. Sc.. Cristiano Leite de Castro

  
\_\_\_\_\_ UFLA

D. Sc. Francisco Carlos Gomes

  
\_\_\_\_\_ UFLA

D. Sc. Tadayuki Yanagi Junior

  
\_\_\_\_\_ UFLA

D. Sc. Wilian Soares Lacerda

  
\_\_\_\_\_ UFLA

**LAVRAS - MG  
2011**

*Aos meus pais, Adilson e Iracema, a minha irmã Christiane, a minha avó  
Helena, a Moysa.*

*Aos meus amigos.*

**Dedico.**

## **AGRADECIMENTOS**

Ao meu pai Adilson, que me apoiou em todos os momentos. A minha mãe Iracema, que mesmo ausente se fez presente sempre. A minha avó Helena, que sempre me ajudou de todas as formas.

A minha irmã Christiane, pelo apoio incondicional e troca de conhecimentos durante toda a caminhada. A Moysa, por todo carinho e companheirismo.

Aos meus amigos, que sempre foram verdadeiros irmãos.

À todos que, de alguma forma, me ajudaram durante o curso de Sistemas de Informação, meus sinceros agradecimentos.

Ao professor Tadayuki, por todo apoio e amizade. Ao professor Wilian, que me ajudou sempre que necessitei. A Patrícia por toda a ajuda. Além de terem depositado suas confianças em mim e me ajudaram a desenvolver este trabalho. Pelo comprometimento e pela paciência.

“O único lugar aonde o sucesso vem antes do trabalho é no dicionário”  
Albert Einstein

## RESUMO

Dentre os desafios enfrentados pela avicultura de corte, destaca-se a importância do ambiente de criação. Quando as condições do ambiente interno no galpão avícola não são adequadas e os animais são expostos a condições de estresse térmico, ocorre a diminuição do bem estar, podendo comprometer o seu crescimento e desempenho. Um animal pode demonstrar seu conforto ou desconforto em suas respostas produtivas. Diante do exposto, este trabalho tem como objetivo geral prever o ganho de peso de frangos de corte durante as primeiras três semanas de vida. Para prever o desempenho produtivo dos frangos, uma rede neural artificial foi desenvolvida com base em dados da literatura e experimental, tendo como dados de entrada a idade do frango (semanas), a temperatura (°C) e a umidade relativa do ar (%) no ambiente de criação, e, como variável de saída o ganho de peso dos animais (g). Para obtenção da rede neural artificial (RNA), houve necessidade de se fazer um tratamento inicial dos dados. Primeiramente, os dados de temperatura, umidade relativa do ar, temperatura e ganho de peso foram normalizados e posteriormente normalizados novamente, entretanto, em relação a semana de vida da ave. Para a construção da RNA foi utilizada uma topologia composta de duas redes, sendo a saída da primeira RNA uma das entradas da segunda, que além desta entrada também utilizou as mesmas entradas da primeira RNA e todos os dados tratados referentes a temperatura e umidade relativa do ar, sendo sua saída o ganho de peso. A rede neural proposta mostrou-se adequada em aproximar os ganhos de peso de frangos na fase de aquecimento, tendo um  $R^2 = 0,8442$ , um desvio padrão médio de 27,1 gramas e erro percentual médio de 0,14.

**Palavras-chave:** Redes neurais artificiais; Avicultura; Modelagem de sistemas biológicos.

## ABSTRACT

Among the challenges facing the poultry industry, highlights the importance of the authoring environment. When environmental conditions in domestic poultry shed are not adequate and the animals are exposed to conditions of heat stress, there is a decrease of well-being, which could compromise their growth and performance. An animal can demonstrate their comfort or discomfort in their productive responses. Given the above, this study aims to predict the overall weight gain of broilers during the first three weeks of life. To predict the productive performance of chickens, an artificial neural network was developed based on literature data and experimental, taking as input the age of the chicken (weeks), temperature ( $^{\circ}$  C) and relative humidity (%) in the authoring environment, and as output variable weight gain of animals (g). To obtain the artificial neural network (ANN), it was necessary to make an initial treatment of the data. First, the data of temperature, relative humidity, temperature and weight gain were normalized and then normalized again, however, for the week of the bird's life. For the construction of RNA was used a topology composed of two networks, with the output of the first entries in the RNA of a second, that beyond this entrance also used the same inputs of the first RNA and treated all data related to temperature and relative humidity air, and its output weight gain. The proposed neural network was adequate to approximate the weight gains of chickens in the heating phase, with an  $R^2 = 0.8442$ , an average standard deviation of 27.1 grams and average percentage error of 0.14.

Keywords: Artificial neural networks, Poultry, modeling of biological systems.

## LISTA DE FIGURAS

Figura 1- Neurônio artificial proposto por McCulloch e Pitts .....	16
Figura 2 - Função degrau.....	17
Figura 3 - Função sigmoideal .....	18
Figura 4 - Função identidade .....	18
Figura 5 - Função gaussiana .....	19
Figura 6 - Treinamento supervisionado.....	22
Figura 7- Rede neural com duas camadas escondidas .....	23
Figura 8 - Fluxo de processamento do algoritmo back-propagation .....	24
Figura 10 - Esquema de posicionamento dos sensores de temperatura e umidade relativa nos galpões de frango.....	29
Figura 11 - Arquitetura RNA auxiliar .....	33
Figura 12 - Arquitetura RNA principal .....	34
Figura 13 - Arquitetura RNA completa .....	35
Figura 14 - Erro médio quadrático de treinamento da RNA auxiliar .....	37
Figura 15 - Erro médio quadrático de treinamento da RNA principal .....	38
Figura 16 - Frequência de ocorrência do desvio absoluto .....	40
Figura 17 - Regressão linear para a variável de saída da RNA.....	41



## LISTA DE TABELAS

Tabela 1 - Exemplo de dados originais .....	30
Tabela 2 - Semanas expressa de forma binária .....	31
Tabela 3 - Dados após processamento .....	31
Tabela 4 - Exemplo de dados normalizados para cada semana a partir da normalização de seu atributo .....	32
Tabela 5 - Exemplo de entrada de dados e saída desejada da RNA principal ...	34
Tabela 6 - Resultados estatísticos da RNA .....	39

## SUMÁRIO

1	Introdução .....	10
1.1	Objetivo .....	11
1.1.1	Objetivo Geral .....	11
1.2	Objetivos Específicos .....	11
1.3	Estrutura do Trabalho .....	11
2	Referencial Teórico .....	13
2.1	Fatores Térmicos no Ambiente de Criação .....	13
2.2	Redes Neurais Artificiais .....	15
2.2.1	Neurônio Artificial .....	15
2.2.2	Lei de Heeb.....	19
2.2.3	Perceptrons .....	20
2.2.4	Redes Neurais de Múltiplas Camadas .....	22
2.2.5	<i>Back-Propagation</i> .....	24
2.2.6	Utilização de Redes Neurais Artificiais.....	25
2.2.7	Trabalhos Relacionados.....	26
3	Metodologia .....	27
3.1	Tipo de Pesquisa .....	27
3.2	Ambiente de Desenvolvimento .....	27
3.3	Procedimentos Metodológicos .....	27
3.3.1	Coleta de Dados .....	27
3.3.2	Tratamento dos Dados .....	29
3.3.3	Desenvolvimento da Rede Neural Artificial .....	32
3.3.4	Análise dos Resultados .....	36
4	Resultados.....	37
4.1	Treinamento .....	37
4.2	Validação .....	38
5	Conclusão .....	42
5.1	Trabalhos Futuros .....	42
6	Referências Bibliográficas.....	44

## 1 INTRODUÇÃO

Com o aumento populacional e o crescimento do consumo de alimentos, a agroindústria avícola tem se desenvolvido de forma a conseguir produzir mais, gastando menos. Nesse contexto, as agroindústrias estão se preocupando cada vez mais com o ambiente de produção e os fatores que influenciam o desenvolvimento produtivo dos frangos.

A temperatura ambiente e umidade relativa do ar são duas variáveis muito importantes para a criação de frangos, pois estas variáveis estão diretamente ligadas ao conforto térmico dos animais. O controle dessas variáveis pode proporcionar um ambiente adequado para que o desempenho produtivo dos frangos seja maximizado.

A definição dos limites térmicos nos ambientes de produção avícola é uma das dificuldades encontradas pelos produtores. Aproximar o ganho de peso médio dos frangos de um galpão a partir da temperatura e umidade relativa do ar média semanal e a idade do animal em semanas é um ganho estratégico para esses produtores. Com essa aproximação, os produtores, tem a possibilidade planejar melhor o manejo de seu plantel.

Redes neurais artificiais (RNAs) são modelos computacionais, e matemáticos, capazes de generalizar informações após passar por um treinamento específico. A construção de RNAs para a aproximação do ganho de peso de frangos é primordial para o manejo adequado das aves, principalmente em um período no qual o ambiente de produção afeta significativamente o seu desempenho no abate, sendo que, situações de estresse são indesejáveis e podem gerar danos irreversíveis.

## **1.1 Objetivo**

### **1.1.1 Objetivo Geral**

Diante do exposto, este trabalho tem como objetivo geral prever o ganho de peso, de frangos de corte durante as primeiras três semanas de vida. Para prever o ganho de peso dos pintinhos, uma RNA foi desenvolvida com base em dados da literatura e dados experimentais, tendo como dados de entrada a idade do frango (semanas), a temperatura (°C) e a umidade relativa do ar (%) no ambiente de criação, e, como variável de saída o ganho de peso dos animais (g).

### **1.2 Objetivos Específicos**

Os objetivos específicos do trabalho são:

- Construir uma base de dados de ganho de peso de frangos em relação à idade (semanas), a temperatura (°C) e a umidade relativa do ar (%).
- Definir uma arquitetura de RNA de múltiplas camadas que satisfaça as necessidades do problema.
- Implementar um treinamento que se adapte aos dados.

### **1.3 Estrutura do Trabalho**

Este trabalho está estruturado da seguinte maneira:

- O Capítulo 1, previamente descrito, apresenta o Objetivo Geral e Objetivos Específicos do trabalho.
- O Capítulo 2 apresenta o Referencial Teórico, mostrando os principais conceitos utilizados no trabalho.

- O Capítulo 3 mostra a Metodologia do trabalho, detalhando a sequência de atividades, a maneira de condução do trabalho e o modo como os conceitos foram aplicados.
- O Capítulo 4 apresenta os resultados encontrados.
- O Capítulo 5 apresenta as conclusões com base nos resultados obtidos.

## **2 REFERENCIAL TEÓRICO**

Nos últimos anos, com a crescente demanda por alimentos devido ao crescimento populacional mundial, a produção de frangos de corte tem se destacado pelo fornecimento de proteína relativamente acessível economicamente a população. Esta demanda tem proporcionado o desenvolvimento do setor, maximizando a produtividade e minimizando os custos de produção.

Neste contexto, o Brasil ocupa a posição de destaque no cenário internacional, com um aumento de 2% na produção e 22% em movimentação financeira (US\$) de março de 2010 a março de 2011, sendo o maior exportador mundial de carne de frango (SEAPA, 2011).

### **2.1 Fatores térmicos no ambiente de criação**

O ambiente de criação é de grande importância para a avicultura de corte, pois é nele que os fatores térmicos podem ser equilibrados. Quando o animal entra em estresse térmico os fatores fisiológicos e comportamentais são alterados, afetando o seu desenvolvimento produtivo. Definir quais são as condições ideais tem sido um grande desafio para a produção (OLIVEIRA et al., 2006; NAZARENO et al., 2009).

A ave exige, do meio onde habita, condições ideais de ambiente, como temperatura do ar, umidade relativa, pressão atmosférica, luminosidade e nível de pressão sonora. Esses fatores, quando controlados de forma correta, influenciam positivamente para um melhor desenvolvimento e ganho produtivo do frango (OLIVEIRA et al., 2006; SARMENTO et al., 2005).

Quando as condições ambientais no interior da instalação não estão dentro de limites adequados, o ambiente térmico torna-se desconfortável, fazendo que o organismo do animal ajuste-se fisiologicamente para manter sua temperatura,

seja conservando ou dissipando calor. Com isso, ocorre desperdício de energia, resultando na redução da sua eficiência produtiva (MEDEIROS et al., 2005).

De acordo com Oliveira et al. (2006), somente a pouco tempo que a indústria avícola passou a se preocupar com o controle dos fatores termológicos, buscando nas instalações e na ambiência a possibilidade de melhoria nos ganhos produtivos, como forma de diminuir os gastos e maximizar o lucro.

Dentre os fatores ambientais que os frangos estão submetidos, os fatores térmicos, principalmente, a temperatura e a umidade relativa do ar, são os que mais influenciam no índice de bem estar do animal, afetando diretamente o desenvolvimento das aves (OLIVEIRA et al., 2006; NAZARENO et al., 2009). Essa condição de conforto promove grande dificuldade de balanço térmico dentro dos galpões de produção (MENEGALI et al., 2009; NAZARENO et al., 2009).

As aves são animais homeotérmicos e estão em troca contínua de calor com o meio, sendo esse sistema eficiente quando a temperatura ambiente se encontra dentro dos limites ideais. Quando as condições térmicas estão fora desses limites, as aves afetam seu comportamento e utilizam de recursos fisiológicos para se adequarem as condições proporcionadas pelo ambiente (SARMENTO et al., 2005; MENEGALI et al., 2009).

Quando submetidas a temperaturas muito baixas, as aves se agrupam com o objetivo de diminuir a perda de calor corporal para o meio, nesta situação o crescimento é lento, diminuindo a conversão alimentar das aves, além da procura por água e alimento serem reduzidas (OLIVEIRA et al., 2006; SARMENTO et al., 2005; MENEGALI et al., 2009; NAZARENO et al., 2009).

Quando submetidas a altas temperaturas, as aves se distanciam umas das outras, ocorrendo a diminuição de atividade física e de produção interna de calor, fazendo com que o calor metabólico seja transferido para a superfície do corpo, na tentativa de liberá-lo para o ambiente. Nestas condições, as aves

reduzem o consumo de alimento e água (OLIVEIRA et al., 2006; SARMENTO et al., 2005; MENEGALI et al., 2009; NAZARENO et al., 2009).

De acordo com Oliveira et al. (2006), a capacidade das aves de suportar calor é inversamente proporcional ao teor de umidade relativa do ar. Pois quanto maior a umidade relativa do ar, maior a dificuldade do animal de remover calor interno para o ambiente pelas vias aéreas, o que leva ao aumento da frequência respiratória. Essa manutenção da temperatura, via esse processo, para manter a homeotermia da ave promove mudanças comportamentais e fisiológicas, que podem comprometer seu desempenho.

## **2.2 Redes neurais artificiais**

As redes neurais artificiais (RNAs) foram desenvolvidas com intuito de simular matematicamente o comportamento de um neurônio biológico. Sua forma de conhecimento é representada em forma de aprendizagem através da experiência. Constituindo uma das áreas da inteligência artificial, as RNAs são normalmente utilizadas nos problemas em que é necessário algum tipo de aprendizagem (BRAGA et al., 2007; HAYKIN, 2001).

### **2.2.1 Neurônio artificial**

Inicialmente o neurônio artificial foi proposto em 1943, por McCulloch e Walter Pitts, tentando se assimilar com o que se sabia do funcionamento do neurônio biológico. O Neurônio artificial ou matemático recebe sinais de entrada e devolve um único sinal de saída. Sua descrição matemática resultou em um modelo com  $n$  terminais de entrada (dendritos) que recebem os valores  $x_1, x_2, \dots, x_n$ , que representam as entradas e apenas uma saída denominada  $y$  (axônios). Dendritos e axônios são representados matematicamente pelas sinapses e a intensidade da ligação é representada por uma grandeza denominada peso



sináptico, simbolizada pela letra  $w$  (Figura 1) (BRAGA et al., 2007; LUDWIG JUNIOR & MONTGOMERY, 2007; MEDEIROS, 2006).




Figura 1- Neurônio artificial proposto por McCulloch e Pitts

Um neurônio biológico dispara quando a soma dos impulsos recebidos ultrapassa o seu limiar de excitação. Esse comportamento é representado pelo neurônio artificial de forma que quando as entradas,  $x$ , são apresentadas aos neurônios e multiplicadas pelos pesos sinápticos correspondentes,  $w$ , e então somados, esse total representa a saída  $y$ . Esse foi o primeiro modelo de neurônio artificial, proposto por McCulloch e Pitts, também conhecido como neurônio MCP, referenciando as iniciais de seus criadores (LUDWIG JUNIOR & MONTGOMERY, 2007; BRAGA et al., 2007).

Em neurônios naturais os axônios funcionam como filtros de frequência, para que quando houver alguma sinapse, a transferência seja feita com a frequência correta. Em neurônios artificiais são utilizadas funções matemáticas que simulam o funcionamento dos axônios naturais, as funções de ativação, que quando os valores de entrada  $x = (x_1, x_2, \dots, x_n)$  e seus respectivos pesos  $w = (w_1, w_2, \dots, w_n)$  são apresentados a estas funções, resultam em um padrão de saída. Dentre as principais funções de ativação podem se destacar a função degrau

(Equação 1) (Figura 2), função sigmoïdal (Equação 2) (Figura 3), ativação linear (Equação 3) (Figura 4) e gaussiana (Equação 4) (Figura 5) (LUDWIG JUNIOR & MONTGOMERY, 2007; BRAGA et al., 2007).

$$f(u) = \begin{cases} 0, & \sum_{i=0}^n x_i w_i < \emptyset \\ 1, & \sum_{i=0}^n x_i w_i \geq \emptyset \end{cases} \quad (1)$$




Figura 2 - Função degrau

$$f(u) = \frac{1}{1 + e^{-\beta u}} \quad (2)$$

em que  $\beta$  é a inclinação da função.




Figura 3 - Função sigmoidal

$$f(u) = u$$

(3)




Figura 4 - Função identidade

$$f(u) = e^{-\frac{(u-\mu)^2}{r^2}} \quad (4)$$

em que  $\mu$  é o centro e  $r$  é o raio de abertura da função.




Figura 5 - Função gaussiana

### 2.2.2 Lei de Heeb

Aprendizado de máquina é uma área da inteligência artificial cujo objetivo é desenvolver técnicas computacionais sobre o aprendizado, bem como a construção de sistemas capazes de adquirir conhecimento de forma automática, para inserção de conhecimento em computadores (BATISTA, 2003).

A primeira lei de aprendizado foi proposta por Donald Hebb, denominada lei de Hebb, em 1949, sua proposta de aprendizagem era baseada no aprendizado humano, onde ele defendia a tese que o condicionamento psicológico clássico está igualmente presente em qualquer animal, por ser uma

propriedade de neurônios (LUDWIG JUNIOR & MONTGOMERY, 2007; MEDEIROS, 2006).

Hebb propôs que uma conexão sináptica deve ser ajustada proporcionalmente com o sincronismo dos neurônios. Se dois neurônios de lados distintos de uma sinapse são ativados sincronicamente, essa ligação deve ser fortalecida. Caso eles sejam ativados assincronicamente essa ligação deve ser enfraquecida ou até mesmo eliminada (BRAGA et al., 2007; HAYKIN, 2001).

“A interpretação do postulado de Hebb para as redes neurais artificiais é que o ajuste dos pesos no tempo  $t$  deve ser proporcional ao produto dos valores de entrada e saída da rede” (BRAGA et al., 2007), descrito na Equação 5.

$$\Delta w_{ij}(t) = \eta y_i(t)x_j(t) \quad (5)$$

Em que  $\eta$  é uma constante positiva denominada taxa de aprendizado.

### 2.2.3 Perceptrons

Com o desenvolvimento dos primeiros computadores digitais o pensamento de que se podia desenvolver uma inteligência artificial por meio de operadores lógicos básicos era bastante aceita na época. Em 1958 Frank Rosenblatt propôs o conceito de aprendizagem em redes neurais. O modelo proposto por Rosenblatt, conhecido como perceptrons, era composto de uma estrutura de rede de neurônios MCP (McCulloch-Pitts) e uma regra de aprendizado (BRAGA et al., 2007). Esse modelo era composto por apenas uma camada e tinha como saída um valor binário (LUDWIG JUNIOR & MONTGOMERY, 2007; HAYKIN, 2001).

O aprendizado é feito conforme os ajustes dos pesos sinápticos. Para o perceptron esse ajuste é feito a partir da Regra Delta, criada por Widrow and Hoff em 1960. Essa regra consiste em ajustar os pesos  $w$  a partir do erro da resposta da rede. Atribuem-se valores iniciais aleatórios aos pesos. É

apresentado um conjunto de valores de entrada  $x$  e a sua respectiva saída  $y$  e então é calculada a resposta da rede e comparado com os valores de saída desejados. Caso a diferença entre os valores (erro) não seja aceitável, é feito o ajuste dos pesos proporcionalmente com o erro encontrado (Equação 6), sendo calculada novamente a resposta da rede e seu erro. Esse processo é repetido até que se encontre o erro mínimo objetivado. Esse treinamento que compara uma saída desejada com a obtida é conhecido como treinamento *on-line* ou supervisionado (Figura 6) (MEDEIROS, 2006; LUDWIG JUNIOR & MONTGOMERY, 2007; HAYKIN, 2001).

$$w(i,j)_{T+1} = w(i,j)_T + \eta E(j)_T x_i \quad (6)$$

em que:

- $w(i,j)_{T+1}$ : valor do peso corrigido;
- $w(i,j)_T$ : valor do peso na iteração anterior;
- $E(j)_T$ : valor do erro para o neurônio  $j$ ;
- $T$ : iteração;
- $j$ : índice do neurônio;
- $i$ : índice do sinal de entrada;
- $x(i)$ : sinal de entrada.

O erro ( $E(j)$ ) é a diferença entre o valor calculado ( $y_c$ ) na saída da rede com o valor desejado ( $y_d$ ) (Equação 7).

$$E(j) = y_d(i) - y_c(i) \quad (7)$$

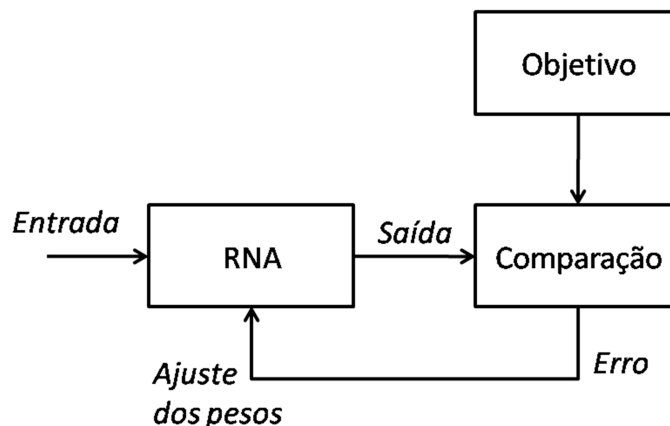


Figura 6 - Treinamento supervisionado

#### 2.2.4 Redes neurais de múltiplas camadas

O perceptron simples, ou de única camada é um discriminador, por conseguir apenas solucionar problemas cujo os dados são linearmente separáveis no espaço de entrada. Essa limitação desmotivou os estudiosos da época que sabiam da existência de RNAs de múltiplas camadas, mas não sabiam como treiná-las. Esse problema foi apenas solucionado em 1986 com a criação do algoritmo back-propagation (BRAGA et al., 2007; HAYKIN, 2001; MCCLELLAN & RUMELHART, 1987).

Essa inexistência ou desconhecimento de um algoritmo de treinamento de redes neurais de múltiplas camadas foi uma das principais causas pela falta de interesse nos estudos de RNAs da década de 70. Minsky e Pappert publicaram um livro chamado “Perceptrons” onde provaram que RNAs de camada simples (única camada) somente podem resolver problemas linearmente separáveis. Essa publicação causou grande diminuição das pesquisas em redes neurais artificiais e seus financiamentos (BRAGA et al, 2007; HAYKIN, 2001).

RNAs de múltiplas camadas tem poder computacional e matemático muito maior que redes neurais de camada simples. Com duas camadas

escondidas (Figura 7), RNAs de múltiplas camadas podem resolver problemas de classificação linearmente separáveis ou não, podendo ser aproximado por uma rede neural artificial com apenas duas camadas escondidas. O poder de aproximação dependerá da arquitetura da rede e do número de neurônios em cada camada escondida (BRAGA et al., 2007; HAYKIN, 2001).




Figura 7- Rede neural com duas camadas escondidas

O número de neurônios em uma RNA determina a sua capacidade de generalização, tanto quanto sua qualidade na resolução do problema. A determinação do número de neurônios depende da complexidade do problema, no entanto não existem estudos que provem como deve ser feita essa distribuição de neurônios por camada. Assim essa é uma etapa comumente empírica no desenvolvimento de RNAs (BRAGA et al., 2007; MEDEIROS, 2006; LUDWIG JUNIOR & MONTGOMERY, 2007; HAYKIN, 2001).



### 2.2.5 *Back-propagation*

O algoritmo *back-propagation* (retro propagação) é uma generalização da Regra Delta em redes de neurônios de múltiplas camadas. Esse treinamento ocorre em duas fases, sendo que em cada fase a rede de neurônios é percorrida em um sentido. Essas fases são denominadas fase *forward* e fase *backward* (Figura 8). A fase *forward* é utilizada para definir uma saída para um dado padrão de entrada. A fase *backward* utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões (LUDWIG JUNIOR & MONTGOMERY, 2007; BRAGA et al., 2007).




Figura 8 - Fluxo de processamento do algoritmo *back-propagation*

A fase *forward* consiste nos seguintes procedimentos:

1. A entrada  $x$  é apresentada à primeira camada  $C_0$  da rede, a saída dessa camada proverá como entrada da camada seguinte  $C_1$ , então as saídas de  $C_1$  serão as entradas de  $C_2$ , esse processo continua até que se atinja a camada final  $C_k$ .

2. As saídas da última camada é comparada com a saída desejada, e então é calculado o erro obtido na rede e inicia-se a fase *backward*.

O objetivo dessa fase é obter o erro total da rede neural, ou seja, o erro da saída após a propagação do sinal em todas as camadas da rede. A Equação 7 descreve como é calculado esse erro da camada de saída ( $E_s$ ).

A fase *backward* consiste nos seguintes procedimentos:

1. A partir da última camada até chegar na camada de entrada:
  - a. Os nós da camada atual ajustam seus pesos de forma a reduzir os erros.
  - b. O erro de um nó das camadas intermediárias,  $C_i$ , é calculado utilizando os erros dos nós das camadas seguintes,  $C_{i+1}$ , conectados a eles, ponderados pelos pesos das conexões entre eles.

### 2.2.6 Utilização de redes neurais artificiais

Redes neurais artificiais foram criadas para assimilar matematicamente o comportamento de um neurônio biológico e assim auxiliar na resolução de problemas complexos e simular a inteligência humana. Com grande poder de aproximação, predição, classificação e regressão, o uso de redes neurais artificiais é grande para a resolução de problemas (BRAGA et al., 2007; LUDWIG JUNIOR & MONTGOMERY, 2007; MEDEIROS, 2006; HAYKIN, 2001).

Do ponto de vista de modelagens de sistemas biológicos, as redes neurais artificiais tem sido grande objeto de estudo. A sua utilização deve tomar alguns cuidados, como a sua arquitetura, função de ativação, parâmetros de

treinamento, entre outros (WU & FURBER, 2010; BRAGA et al., 2007; HAYKIN, 2001).

### **2.2.7 Trabalhos relacionados**

Reali & Salle (2004), utilizaram redes neurais artificiais para explicar os possíveis fenômenos que ocorrem na criação de frangos de corte. Os autores concluíram que as redes neurais desenvolvidas ofereceram critérios objetivos, que podem auxiliar as decisões dos responsáveis pela gerência na produção de frangos de corte.

Ao criar modelos matemáticos para estimar GP de frangos adultos em função da T, UR e velocidade do ar (V), Medeiros (2001) encontrou valores de  $R^2 = 0,89$ . Ponciano (2011) utilizou uma técnica de inteligência artificial, sistemas *fuzzy*, para aproximação de GP de frangos de corte nas primeiras três semanas de vida do animal. Para isso foi utilizado como variáveis de entrada a idade das aves em semanas e T e UR média semanal. Os valores de desvio padrão, desvio absoluto, erro percentual e coeficiente de determinação ( $R^2$ ) determinados foram de 14,75 g, 20,86 g, 11,98% e 0,9753, respectivamente. Estes resultados indicam que o modelo *fuzzy* proposto teve precisão adequada para a predição do GP das aves.

### **3 METODOLOGIA**

Este capítulo descreve a metodologia usada no trabalho e que possibilitou que fossem alcançados os objetivos da pesquisa. Na primeira seção será apresentada a classificação da pesquisa quanto à natureza, ao objetivo e aos procedimentos. Em seguida serão descritos os procedimentos metodológicos da pesquisa.

#### **3.1 Tipo de pesquisa**

Foi usado o tipo de pesquisa analítica que é o método mais comum de gerar/obter conhecimento sobre programas e algoritmos. No projeto buscam-se informações sobre sistemas e algoritmos já existentes, comparando-os a fim de se desenvolver o projeto em questão.

#### **3.2 Ambiente de desenvolvimento**

Para o desenvolvimento da RNA de múltiplas camadas, inclusive o seu treinamento foi utilizado o ambiente de desenvolvimento integrado (IDE) Scilab®, com auxílio da biblioteca ANN Toolbox (<http://www.scilab.org/>).

#### **3.3 Procedimentos metodológicos**

A pesquisa possui basicamente quatro etapas: coleta de dados, tratamento, desenvolvimento da RNA e análise dos resultados obtidos.

##### **3.3.1 Coleta de dados**

Foram coletados dados para a criação de um banco de dados para o treinamento e validação da RNA. Esses dados tiveram origem da literatura e de experimentos.

### 3.3.1.1 Dados da literatura

Para o treinamento e validação da rede neural artificial, foram pesquisados dados oriundos da literatura relacionados à frangos de corte das linhagens Cobb e Cobb500 na fase de aquecimento com informações semanais de temperatura (°C), umidade relativa do ar (%) e ganho de peso (g).

### 3.3.1.2 Coleta de dados experimentais

Além dos dados da literatura, também foram utilizados dados de experimento de campo realizado numa granja comercial com frangos machos da linhagem Cobb, no município de São Sebastião do Oeste – MG, situado na latitude 20° 16' 33" S e longitude 45° 00' 18" W, altitude 780 m, no período de 28 de setembro a 19 de outubro de 2010.

No experimento, foram utilizados dois galpões estruturalmente idênticos, orientados na direção nordeste - sudoeste, com 160 m de comprimento e 13 m de largura; 2,45 m de pé-direito, cobertura de telhas de cimento amianto de 6 mm de espessura, piso de concreto, cama de casca de arroz, cortinas laterais e forro de lona plástica amarela. Foram utilizadas cortinas duplas nas laterais do galpão (uma interna e outra externa).

As coletas de temperatura (T) e umidade relativa (UR) foram feitas a cada 5 minutos durante os primeiros 21 dias de idade das aves, por meio de sensores registradores de temperatura e umidade relativa modelo Hobo Pro Series, da fabricante Onset<sup>®</sup>, com precisão de  $\pm 3\%$  da leitura.

Os dois galpões de frangos foram divididos ao meio, de forma que os pintinhos ficassem separados entre os lados nordeste e sudoeste do galpão sem, no entanto, haver diferença alguma no manejo realizado entre os dois lados. Os sensores/registradores de T e UR acompanhavam essa movimentação da contenção, tendo estes sido instalados conforme indicado na Figura 10, onde L representa a largura da contenção e C, o comprimento.




Figura 9 - Esquema de posicionamento dos sensores de temperatura e umidade relativa nos galpões de frango.

Diariamente, de cada um dos dois lados dos galpões, 30 pintinhos, que visualmente aparentavam ter o tamanho médio do lote, eram pesados no período da manhã e, posteriormente, calculada a média de cada um dos lotes para que fosse feito o acompanhamento do ganho de peso do lote, totalizando 60 animais em cada galpão. As medições de consumo de ração e conversão alimentar não foram feitas devido à impossibilidade de se alterar o manejo da granja.

### 3.3.2 Tratamento dos dados

Foram coletadas 91 repetições de dados constituídos de temperatura (T, °C), umidade relativa do ar (UR, %), semana (ud) e ganho de peso (GP, g) (Tabela 1), porem apenas 75 dessas repetições forram usadas, para evitar duplicidade de dados, pois alguns representavam condições similares de ambiente termico. Como o algoritmo da biblioteca utilizada têm a função sigmoidal como ativação, em que a saída é expressa em um número real com valor entre 0 e 1, os dados tiveram que ser tratados para melhores resultados da RNA.

Tabela 1 - Exemplo de dados originais

Semana (ud)	T (°C)	UR (%)	GP (g)
1	29,3	69,6	152
1	24,3	55,75	101,00
2	24,6	62,35	244,00
2	26,9	60,60	255,50
3	28,46	65,70	338,10
3	29	44,00	438,19

Os dados que eram expressos de forma contínua, temperatura, umidade relativa e ganho de peso, foram normalizados e quantificados para cada atributo, ficando expressos como uma porcentagem da diferença entre o mínimo e o máximo de sua classe, utilizando a Equação 8 para isso.

$$V_n = \frac{(V_a - V_{mim})}{(V_{max} - V_{mim})} \quad (8)$$

em que:

$V_n$ : novo valor;

$V_a$ : valor atual;

$V_{max}$ : valor máximo da classe;

$V_{min}$ : valor mínimo da classe.

O parametro referente à semana foi binarizado, ficando dividido em três variáveis diferentes, semana 1, semana 2 e semana 3. A inclusão em uma classe foi feita de forma que garantisse a exclusão mútua das demais classes, assim um dado não poderia ser classificado em duas semanas diferentes (Tabela 2).

Tabela 2 - Semanas expressa de forma binária

Semana 1	Semana 2	Semana 3
1	0	0
0	1	0
0	0	1

Assim os dados ficaram divididos em cinco atributos, sendo três para as semanas, uma para temperatura ( $T_p$ ), uma para umidade ( $UR_p$ ) e uma para ganho de peso ( $GP_p$ ) (Tabela 3).

Tabela 3 - Dados após processamento

	Semana			$T_p$	$UR_p$	$GP_p$
	1	2	3	(%)	(%)	(%)
1	0	0	0	0,733813	0,772	0,150048
1	0	0	0	0,374101	0,495	0,047234
0	1	0	0	0,395683	0,627	0,335517
0	1	0	0	0,561151	0,592	0,358701
0	0	1	0	0,673381	0,694	0,52522
0	0	1	1	0,71223	0,26	0,726998

Sendo a semana um dado muito significativo para o ganho de peso, pois a cada semana que o frango ganha uma quantidade sempre maior de peso. Foi observado em testes de ajustes da RNA que a ela interpreta a semana como o dado mais importante e deixa os dados referentes a temperatura e umidade relativa como secundários, dessa forma a aproximação feita pela RNA não seria adequada. Assim, para um melhor entendimento da RNA, três novas entradas tiveram que ser geradas.

A partir dos dados normalizados (Tabela 3) foram gerados dados referentes a temperatura ( $T_s$ ), umidade relativa do ar ( $UR_s$ ) e ganho de peso ( $GP_s$ ). Para isso os dados foram novamente processados utilizando a Equação 8,



mas agora os dados foram normalizados em relação a semana de idade do frango, sendo o valor máximo do atributo o maior valor da semana e o valor mínimo do atributo o menor valor de sua semana (Tabela 4).

Tabela 4 - Exemplo de dados normalizados para cada semana a partir da normalização de seu atributo

Semana			T	UR	GP
1	2	3	(%)	(%)	(%)
1	0	0	0,678261	0,772	0,617676
1	0	0	0,243478	0,495	0,19444
0	1	0	0,420168	0,398902	0,256855
0	1	0	0,595874	0,342377	0,330701
0	0	1	0,715049	0,587121	0,510761
0	0	1	0,756302	0	0,718684

### 3.3.3 Desenvolvimento da rede neural artificial

Primeiramente foi desenvolvida uma RNA auxiliar de pré-processamento utilizando temperatura ( $T_s$ ) e umidade relativa do ar ( $UR_s$ ) normalizados para cada uma das três semanas de idade do frango e como saída esperada o ganho de peso ( $GP_s$ ), também normalizado para cada semana, como exemplificados na Tabela 4.

Essa RNA definida de forma empírica tinha uma arquitetura de dois neurônios de entrada, dezesseis na primeira camada escondida, quatro na segunda camada escondida e um como saída (Figura 11). Seus parâmetros de treinamento foram definidos com 0,1 como taxa de aprendizado, 1 como termo de *momentun* e 2500 épocas de treinamento.

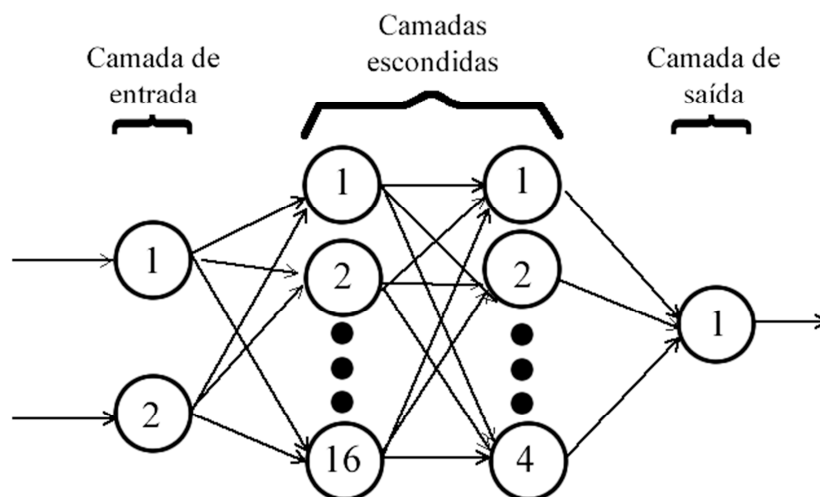


Figura 10 - Arquitetura RNA auxiliar

Essa RNA auxiliar ( $RNA_{aux}$ ) tem como objetivo criar uma nova entrada para a RNA principal ( $RNA_p$ ) com sua saída ( $Y_{RNA_{aux}}$ ).

No desenvolvimento da RNA principal foram utilizados como entrada a semana expressa em binário, temperatura ( $T_p$ ) e umidade relativa do ar ( $UR_p$ ) normalizados para todos os dados de seus atributos, temperatura ( $T_s$ ) e umidade relativa do ar ( $UR_s$ ) normalizados para cada uma das três semanas de idade do frango e a saída da RNA auxiliar ( $Y_{RNA_{aux}}$ ) e como saída o ganho de peso ( $GP_p$ ) normalizado, como exemplificado na Tabela 5.

Tabela 5 - Exemplo de entrada de dados e saída desejada da RNA principal

Entrada								Saída
Semana	$T_p$	$UR_p$	$T_s$	$UR_s$	$Y_{RNA\ aux}$			$GP_p$
1	0	0	0,733813	0,772	0,678261	0,772	0,593289	0,150048
1	0	0	0,374101	0,495	0,243478	0,495	0,387704	0,047234
0	1	0	0,395683	0,627	0,420168	0,398902	0,256855	0,335517
0	1	0	0,561151	0,592	0,595874	0,342377	0,330701	0,358701
0	0	1	0,673381	0,694	0,715049	0,587121	0,441169	0,52522
0	0	1	0,71223	0,26	0,756302	0	0,510761	0,726998

A arquitetura dessa RNA foi definida de forma empírica com oito neurônios de entrada, trinta e dois na primeira camada escondida, dezesseis na segunda camada escondida e um como saída (Figura 12), em seu treinamento foi utilizado o algoritmo *backpropagation* com momento. Seus parâmetros de treinamento foram definidos de forma empírica, tendo os valores de 0,1 como taxa de aprendizado, 0,7 como termo de *momentum* e 90 épocas de treinamento.

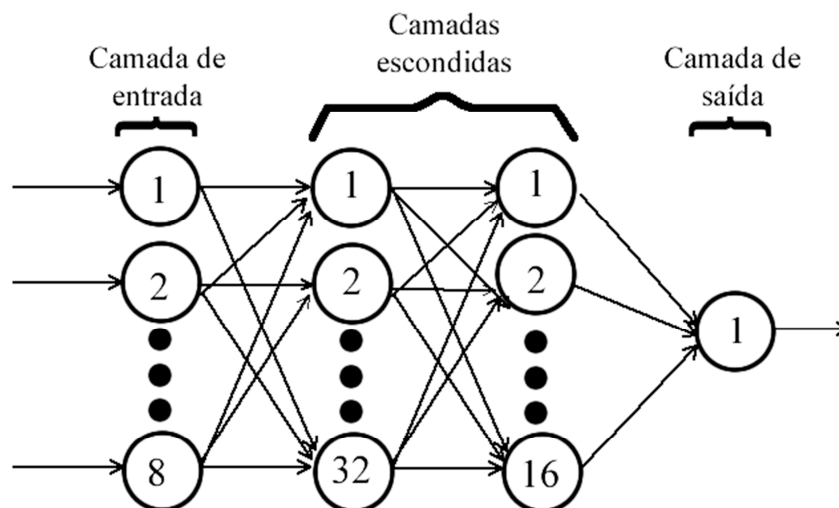


Figura 11 - Arquitetura RNA principal

Ao final obteve-se um modelo de RNA composto de duas redes, com uma recorrência de entrada. Sendo a primeira, a RNA auxiliar que tem sua saída como entrada da RNA principal que também utiliza as entradas da RNA auxiliar (Figura 13). Mais informações de RNAs que utilizam topologias com recorrência, como as topologias de Jordan e de Elman, podem ser encontrados em Braga et al (2007).




Figura 12 - Arquitetura RNA completa

### **3.3.4 Análise dos resultados**

Após o desenvolvimento e treinamento da RNA, a mesma foi validada com parte dos dados da literatura e experimental, na proporção de 13%, que não foram utilizados no treinamento. Esta validação permitiu a avaliação do grau de generalização da RNA desenvolvida.

Além disso, nessas análises também foram aplicadas análises estatísticas, entre elas o coeficiente de determinação ( $r^2$ ), que calcula o grau de associação de duas variáveis, e o erro médio quadrático, que calcula o erro médio elevado ao quadrado, para que se possa fazer uma análise precisa sobre o acerto da RNA desenvolvida.

## 4 RESULTADOS

### 4.1 Treinamento

Durante o treinamento, o erro médio quadrático de cada época foi monitorado nos treinamentos feitos nas duas RNA's construídas (Figura 14 e 15). O erro médio quadrático final da RNA auxiliar é relativamente alto quando comparado a RNA principal, 1,77 e 0,33, respectivamente. Mas como o intuito dessa rede é um pré-processamento, esse parâmetro não representa o índice de erro da aproximação final. A RNA principal apresentou um erro médio quadrático baixo no final do seu treinamento, isso representa que ao concluir o treinamento a aproximação em relação aos dados de treinamento foi satisfatória considerando o baixo erro apresentado.




Figura 13 - Erro médio quadrático de treinamento da RNA auxiliar




Figura 14 - Erro médio quadrático de treinamento da RNA principal

## 4.2 Validação

Para a validação, os dados de saída (GP) foram transformados para o valor absoluto, na unidade de grama, fazendo denormalização. Após a transformação, foram feitos os métodos estatísticos para calcular a qualidade de aproximação da RNA. Comparando os valores de ganho de peso simulados pela RNA com os observados, obteve-se o máximo, mínimo, média e mediana do erro médio quadrático, desvio absoluto, erro percentual e coeficiente determinístico (Tabela 6).

Tabela 6 - Resultados estatísticos da RNA

		RNA	
Ganho de peso (g)	Desvio absoluto	Máximo	69,1
		Mínimo	1,3
		Média	38,3
		Mediana	36,5
	Desvio padrão	Máximo	48,90
		Mínimo	0,93
		Média	27,10
		Mediana	25,82
	Erro percentual	Máximo	27%
		Mínimo	1%
		Média	14%
		Mediana	15%
$R^2$		0,8442	
Erro médio quadrático		13,79	

Por meio da Tabela 6, verificou-se que o coeficiente de determinação ( $R^2$ ), desvio absoluto médio, desvio padrão médio, foram de 0,8442, 38,34 g, 27,5g e 0,14% respectivamente. Esses resultados indicam que a RNA proposta teve uma boa precisão para a aproximação do ganho de peso semanal das aves.

Foi observada a frequência do desvio absoluto (Figura 16) e observa-se que em 100% das ocorrências o erro foi menor que 70 gramas, sendo 10% menor que 10g, 40% menor que 30g, 70% menor que 50g e 20% maior que 70g.



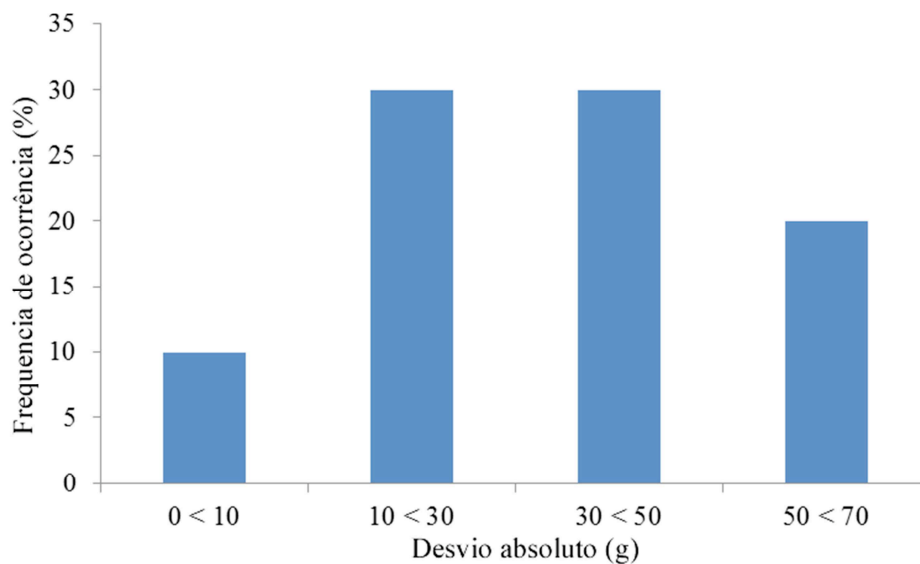


Figura 15 - Frequência de ocorrência do desvio absoluto

As relações funcionais entre o GP observado e simulado pela RNA estão ilustrados na Figura 17, sendo que a regressão linear, com ajuste da reta passando pela origem, apresentam  $R^2 = 0,8442$ . Apesar dos resultados encontrados por Ponciano (2011) se mostrarem mais satisfatórios que o deste trabalho, o mesmo ainda apresenta uma boa precisão em se aproximar os valores de GP. Porém, observa-se ainda, que a RNA proposta ainda pode ser melhorada, caso se utilize um banco de dados maior.




Figura 16 - Regressão linear para a variável de saída da RNA

## 5 CONCLUSÃO

Concluiu-se que técnicas de inteligência artificial podem ser eficazes em se aproximar dados de respostas fisiológicas de frangos a partir das variáveis climáticas.

Baseado nos resultados obtidos, conclui-se que a RNA desenvolvida mostrou-se adequada para a aproximação de ganhos de peso de frangos de 1 a 3 semanas de idade, sendo que o valor do coeficiente de determinação foi de 0,8442.

Para construção da RNA utilizou-se um modelo composto de duas redes neurais com entradas em comum. Pode-se concluir que com a utilização de uma RNA de pré-processamento utilizando os dados menos significativos (T e UR) em sua entrada resultou em uma maior generalização dos resultados em comparações estatísticas em relação a outros modelos de RNA testadas.

Observou-se também que o tratamento dos dados por meio da normalização foi importante para obtenção de melhores resultados na aproximação, tendo em vista que os dados brutos não tem uma distribuição uniforme e com sua utilização, sem esse tratamento, os resultados obtiveram erros estatisticamente maiores.

O uso desses resultados ajuda no suporte à decisão do controle de climatização dos galpões de produção, possibilitando, assim otimizar produção.

### 5.1 Trabalhos Futuros

Este trabalho pode gerar novos frutos, sua metodologia pode ser aproveitada e alguns novos métodos podem ser testados, como:

- Criação de um banco de dados maior para um treinamento mais preciso.

- Utilizar outras técnicas de inteligência artificial com o mesmo propósito a fim de se selecionar a técnica mais adequada.
- Utilização da RNA já treinada em dispositivos de automatização de climatização de galpões de produção.
- Uso de outros algoritmos de treinamento para os neurônios da RNA.

## 6 REFERÊNCIAS BIBLIOGRÁFICAS

BATISTA, G. E. A. P. A. *Pré-processamento de dados em aprendizado de máquina supervisionado*. Tese (Doutorado em Ciências de Computação e Matemática Computacional) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2003. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/55/55134/tde-06102003-160219/>>. Acesso em: 2011-12-06.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B.. *Redes Neurais Artificiais – Teoria e Aplicações*, 2ª edição: Editora LTC, 2007, 226 p.

CARVALHO, J. C. C. *Complexos enzimáticos em rações fareladas para frangos de corte*: 64f. Dissertação (Mestrado em Zootecnia) – Universidade Federal de Lavras - UFLA, Lavras, 2006.

GOMES, G. A. *Nutrição pós-eclosão de frangos de corte*: Dissertação (Mestrado) Faculdade de Zootecnia e Engenharia de Alimentos

GRAÑA, A. L. *Estudo de estratégias nutricionais para frangos de corte*: 102f. Tese (Doutorado em Zootecnia). Universidade Federal de Viçosa - UFV, Viçosa, 2008.

HAYKIN, S. *Redes Neurais – Princípios e práticas*. Editora Bookman, 2ª edição: 2001, 899p.

MCCLELLAN, J. L.; RUMELHART, D. E. *Parallel Distributed Processing Vol. 1: Foundation*. Editora A Bradford book, 1ª edição: 1987, 576p.

LABOISSIÈRE, M. *Farinhas de resíduos de abatedouro avícolas em diferentes graus de processamento em rações pré-iniciais e iniciais de frangos de corte*: 70 f. Dissertação (Mestrado em Medicina Veterinária) – Universidade Federal de Goiás – UFG, Goiânia, 2008.

LIRA, R.C. *Valor nutricional e utilização do resíduo da goiaba (*Psidium guajava* L.) e do tomate (*Lycopersicon esculentum* mill.) na alimentação de frangos de corte*: 105 f. Tese (Doutorado em Zootecnia) – Universidade Federal Rural de Pernambuco, Recife, 2008.

LUIDWIG JUNIOR, O.; MONTGOMERY, E. *Redes Neurais – Fundamentos e Aplicações com programas em C*: Editora Ciência Moderna, 2007, 125p.

MEDEIROS, C. M. *Ajuste de modelos e determinação de índice térmico ambiental de produtividade para frangos de corte*: 115 f. Tese (Doutorado em Engenharia Agrícola) – Universidade Federal de Viçosa, Viçosa, MG, 2001.

MEDEIROS, C. M.; BAÊTA, F. DA C.; OLIVEIRA, R. F. M.; TINÔCO, I. F. F.; ALBINO, L. F. T.; CECON, P. R. *Efeitos da temperatura, umidade relativa e velocidade do ar em frangos de corte*: Engenharia na Agricultura, Viçosa, MG, v.13, n.4, 277-286, Out./Dez., 2005

MEDEIROS, L. F. *Redes Neurais em Delphi*, 2ª edição: Editora Visual Books, 2006, 210p.

MENEGALI, I.; TINÔCO, I. de F. F.; BAÊTA, F. da C.; CECON, P. R.; GUIMARÃES, M. C. de C.;CORDEIRO, M. B. *Ambiente térmico e concentração de gases em instalações para frangos de corte no período de aquecimento*: v.13, (Suplemento), p.984–990, 2009.

MINAFRA, C. S. *Produção e suplementação com  $\alpha$ -amilase de *Cryptococcus flavus* e *Aspergillus Niger HM2003* na dieta de frangos de corte de um a 21 dias de idade*: 141 f. Tese (Doutorado em Bioquímica Agrícola) – Universidade Federal de Viçosa – UFV. Viçosa, 2007.

NAZARENO, A. C.; PANDORFI, H.; ALMEIDA, G. L. P.; GIONGO, P. R.; PEDROSA, E. M. R.; GUISELINI, C. *Avaliação do conforto térmico e desempenho de frangos de corte sob regime de criação diferenciado*: Revista Brasileira de Engenharia Agrícola e Ambiental v.13, n.6, p.802–808, 2009.

OLIVEIRA, R. F. M. de.; DONZELE, J. L.; ABREU, M. L. T. de; FERREIRA, R. A.; VAZ, R. G. M. V.; CELLA P. S. *Efeitos da temperatura e da umidade relativa sobre o desempenho e o rendimento de cortes nobres de frangos de corte de 1 a 49 dias de idade*: R. Bras. Zootec., v.35, n.3, p.797-803, 2006.

PONCIANO, P. F. *Predição do desempenho produtivo e temperatura retal de frangos de corte durante os primeiros 21 dias de vida*: 97 f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Lavras - UFLA. Lavras, 2010.

REALI, E. H.; SALLE, C. T. P. *Utilização de inteligência artificial - (Redes neurais artificiais) no gerenciamento da produção de frangos de corte*: Dissertação de mestrado, Universidade Federal do Rio Grande do Sul. Faculdade de Veterinária. Programa de Pós-Graduação em Ciências Veterinárias, disponível em: <http://www.lume.ufrgs.br/handle/10183/6339>, acessado em de maio de 2011, 2004.

SANTOS, A. L. dos. *Potencial de crescimento, desempenho, rendimento de carcaça e qualidade da carne de diferentes linhagens de frango de corte convencional e tipo caipira*: 95 f. Dissertação (Mestrado em Zootecnia) – Universidade Estadual Paulista, Faculdade de Ciências Agrárias e Veterinárias - UNESP, Jaboticabal, 2004.

SANTOS, G.C. dos. *Alternativas ao uso de promotores químicos de crescimento sobre o desempenho e características de carcaça de frangos de corte*: 67 f. Dissertação (Mestrado em Zootecnia) – Universidade Federal dos Vales do Jequitinhonha e Mucuri - UFVJM. Diamantina, 2010.

SARMENTO, L. G. V.; DANTAS, R. T.; FURTADO, D. A.; NASCIMENTO, J. W. B.; SILVA, JOSÉ H. V. *Efeito da pintura externa do telhado sobre o ambiente climático e o desempenho de frangos de corte*: Agropecuária Técnica, v.26, n.2, p.117–122, 2005.

SEAPA MG. *Balança Comercial do Agronegócio Mineiro e Brasileiro*: [http://www.agricultura.mg.gov.br/index.php?option=com\\_content&view=article&id=1329&Itemid=89](http://www.agricultura.mg.gov.br/index.php?option=com_content&view=article&id=1329&Itemid=89), acessado em 3 de maio de 2011.

SILVA, C.L.S da *Glicerina proveniente da produção de biodiesel como ingrediente de ração para frangos de corte*: Dissertação (Mestrado) - Escola Superior de Agricultura "Luiz de Queiroz", 2010.

SILVEIRA, Marta Helena Dias, *Efeito da adição de enzimas, do nível de energia, da adição de aminoácidos sulfurados e da peletização em dietas para frangos de corte*: 58f. Tese (Doutorado) - Programa de Pós-Graduação em Zootecnia. Universidade Federal de Pelotas, Pelotas - RS, 2008.

THON, M. S. *Níveis de lisina e de arginina digestíveis, de sódio e número de mongin na ração pré-inicial de frangos de corte*, 108 f. Tese (Doutorado em Ciência Animal) – Universidade Federal de Goiás – UFG, Goiânia, 2008.

ZAUK, N.H.F. *Desempenho produtivo, características de carcaças e morfometria intestinal de frangos de corte recebendo dietas pré-iniciais com*

*inclusão de diferentes níveis de extrato de levedura (Saccharmyces cerevisiae):* 140 f. Tese (Doutorado em Nutrição Animal) - Faculdade de Agronomia Eliseu Maciel. Universidade Federal de Pelotas. Pelotas, 2008.

WU, J.; FURBER, S. *A Multicast Routing Scheme for a Universal Spiking Neural Network Architecture: The Computer Journal*: v. 53, n. 3, p. 1525-3511, 2010.