

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
ESPECIALIZAÇÃO EM BANCO DE DADOS**

ANDRÉ LUCAS WIRTH

**APRIMORAMENTO DO MANEJO AVÍCOLA UTILIZANDO
REDE NEURAL ARTIFICIAL: Um estudo de caso real**

MONOGRAFIA DE ESPECIALIZAÇÃO

PATO BRANCO

2017

ANDRÉ LUCAS WIRTH

**APRIMORAMENTO DO MANEJO AVÍCOLA UTILIZANDO
REDE NEURAL ARTIFICIAL: Um estudo de caso real**

Trabalho de Conclusão de Curso, apresentado ao II Curso de Especialização em Banco de Dados, da Universidade Tecnológica Federal do Paraná, campus Pato Branco, como requisito parcial para obtenção do título de Especialista.

Orientador: Prof. Dr. Richardson Ribeiro

Coorientador: Prof. Dr. Dalcimar Casanova

PATO BRANCO

2017

Uma mente necessita de livros da mesma
forma que uma espada necessita de uma pedra
de amolar, se quisermos que se mantenha
afiada

George R. R. Martin



Ministério da Educação
Universidade Tecnológica Federal do Paraná
Câmpus Pato Branco
Diretoria de Pesquisa e Pós-Graduação
II Curso de Especialização em Banco de Dados –
Administração e Desenvolvimento



TERMO DE APROVAÇÃO

APRIMORAMENTO DO MANEJO AVÍCOLA UTILIZANDO REDE NEURAL ARTIFICIAL: Um estudo de caso real.

por

ANDRÉ LUCAS WIRTH

Este Trabalho de Conclusão de Curso foi apresentado em 22 fevereiro de 2017 como requisito parcial para a obtenção do título de Especialista em Banco de Dados. O(a) candidato(a) foi arguido(a) pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Richardson Ribeiro
Prof.(a) Orientador(a)

Marco Antonio Castro Barbosa
Membro titular

Dalcimar Casanova
Membro titular

“O Termo de Aprovação assinado encontra-se na Coordenação do Curso”

RESUMO

WIRTH, André Lucas. APRIMORAMENTO DO MANEJO AVÍCOLA UTILIZANDO REDE NEURAL ARTIFICIAL: Um estudo de caso real. 2017. Monografia II Curso de Especialização em Banco de Dados - Universidade Tecnológica Federal do Paraná. Pato Branco, 2017.

Neste trabalho é mostrado como técnicas de aprendizagem de máquina podem ser empregadas para o aprimoramento das atividades do manejo avícola. O manejo avícola consiste no controle de recursos como água, ração, temperatura, umidade, ventilação e outros. Esses recursos são gerenciados por um especialista humano em criação de aves, denominado avicultor. A maneira como esses recursos são controlados influencia no desenvolvimento das aves, impactando na produtividade. Pesquisas in loco mostram que avicultores com mais expertise geralmente conseguem melhores resultados em termos de produtividade. Diante disso, um modelo de aprendizagem usando regressão linear por meio de uma rede neural artificial é usada para auxiliar avicultores no processo de tomada de decisão. O resultado é um sistema especialista que sugere ao avicultor os recursos a serem empregados.

Palavras-chave: Aprendizagem de máquina. Manejo avícola. Redes neurais artificiais.

ABSTRACT

WIRTH. André Lucas. Improving poultry management using Artificial Neural Networks: A real case study. 2017. 19 f. Monography (II Specialization Course in Database) - Universidade Tecnológica Federal do Paraná. Pato Branco, 2017.

This work shows how machine learning techniques can be used to improve poultry management activities. Poultry management consists of the control of resources such as water, feed, temperature, humidity, ventilation, among others. These resources are managed by a human specialist known as a poultry farmer. The way these resources are controlled influences the development of birds, impacting productivity. On-the-spot surveys show that poultry farmers with more expertise often achieve better productivity results. Therefore, a learning model using linear regression through an artificial neural network is used to assist poultry farmers in the decision-making process. The result is a specialist system that suggests to the poultry farmer the resources to be used.

Keywords: Machine Learning. Poultry Management. Artificial Neural Networks.

SUMÁRIO

1. INTRODUÇÃO	6
2. ALTERNATIVAS PARA MELHORAR AS ATIVIDADES DO MANEJO AVÍCOLA	7
3. CONTRIBUIÇÕES.....	10
3.1 Aquisição e estrutura dos dados	10
3.2 Aplicação da abordagem proposta	13
4. RESULTADOS EXPERIMENTAIS	15
5. CONCLUSÕES E DISCUSSÕES FINAIS.....	17
6. REFERÊNCIAS.....	18

1. INTRODUÇÃO

O agronegócio destinado à criação de aves denomina-se avicultura. Países como Brasil, China e Estados Unidos da América concentram aproximadamente 54% da produção mundial. No Brasil por exemplo, a produção de carne de frango chegou a 13,146 milhões de toneladas em 2015, com um crescimento de 450 mil toneladas comparado ao ano anterior. Já a china e os Estados Unidos da América produziram 13,025 e 17,966 milhões de toneladas, respectivamente. Estima-se que mundialmente, o consumo *per capita* de carne de frango no ano de 2016 foi de 41,25 kg/hab. (ABPA, 2016).

Esses números mostram a importância mundial desse segmento. Um dos fatores mais importantes na avicultura é o manejo das aves, comumente chamado de manejo avícola. Nesse manejo, o avicultor realiza uma série de controles, como por exemplo, o tempo de repouso das aves, temperatura, umidade, ventilação, ração, entre outros. A maneira como esses recursos são controlados influencia no crescimento das aves, impactando na produtividade. A produtividade é melhorada de acordo com os cuidados e conhecimentos do avicultor. Avicultores com mais expertise geralmente conseguem melhores resultados em termos de produtividade.

Nas pesquisas em campo com visitas *in loco*, foi verificado que o controle desses recursos normalmente é difícil, visto que as aves possuem um metabolismo sensível para temperatura, umidade e ventilação. Ademais, um recurso normalmente impacta sobre outro recurso. Por exemplo, controlar a ventilação mínima pode aumentar a temperatura do local onde estão alojadas as aves (aviário). Portanto, não é trivial encontrar os melhores valores para cada recurso. Tendo como objetivo aprimorar o uso dos recursos no decorrer de um lote¹, foi estudado o domínio do problema para desenvolver um sistema computacional especializado ao manejo com técnicas de aprendizagem de máquina. O sistema computacional usa uma rede neural artificial com a técnica de regressão linear. Os dados foram obtidos com sensores instalados no interior de um aviário.

Resultados experimentais mostram que a técnica empregada é capaz de abstrair o conhecimento do especialista para um sistema automatizado. A rede neural artificial mostrou-se capaz de generalizar as amostras fornecidas, levando em conta o bem-estar das aves e a produtividade.

1. Um lote compreende o período de tempo entre a chegada e a saída das aves no aviário.

2. ALTERNATIVAS PARA MELHORAR AS ATIVIDADES DO MANEJO AVÍCOLA

Na avicultura de corte, a produtividade é computada pela quantidade de ração consumida (Rc) e o peso médio² das aves (Pm). O valor dado por $\frac{Rc}{Pm}$ indica a conversão alimentar. Devido ao curto ciclo de vida das aves³, as ações realizadas no manejo, como aumentar, diminuir ou manter recursos, devem maximizar a conversão alimentar. Portanto, o controle dos recursos do manejo consiste em ações para: i) evitar a escassez ou o consumo excessivo do alimento; (iii) evitar o excesso de calor ou temperatura abaixo do desejável; e iv) manter a umidade necessária. O controle não adequado desses recursos implica no bem-estar das aves, ocasionando a prostração, descarte ou morte, bem como problemas ao meio ambiente e produtividade.

Para auxiliar nesse controle, um modelo computacional usando técnicas de inteligência artificial pode ser usado para aperfeiçoar o uso dos recursos durante o processo de tomada de decisão do manejo avícola. Em muitos problemas práticos, os sistemas computacionais podem ser especializados usando técnicas avançadas, como aquelas encontradas na *machine learning*. O uso de sistemas computacionais através de abordagens avançadas como os sistemas de aprendizagem indutivos, são alternativos para tratar de diversos tipos de problemas, por exemplo, controle de tráfico de veículos (RIBEIRO *et al.*, 2012, JIANG *et al.*, 2014), jogos e robótica (BACHRACH *et al.*, 2014, COBO *et al.*, 2013), controle de veículos (AU *et al.*, 2014), aprendizagem coletiva (RIBEIRO, ENEMBRECK, 2013, RIBEIRO *et al.*, 2013) dentre outros.

Neste projeto foi feito o uso de uma regressão linear por meio de uma rede neural artificial utilizando o método de regularização bayesiana. O objetivo é identificar a relação entre as variáveis que indicam a percepção do avicultor com as informações de atividades a serem realizadas no processo de manejo avícola. Em outras palavras, o sistema deve predizer quais valores devem ser usados em cada manejo.

As Redes Neurais Artificiais (RNA) são modelos matemáticos de processamento de informações que possuem característica de desempenho semelhantes as redes neurais biológicas. Tal qual o nosso cérebro, a informação é processada em elementos básicos denominados neurônios, que se comunicam através de conexões. A estas conexões estão

² O peso médio das aves é calculado com amostra de 1% do total de aves vivas de um lote;

³ Neste trabalho o manejo avícola foi realizado para a espécie *gallus gallus domesticus*, conhecida como frango de corte. O ciclo de vida desta ave em um lote é de aproximadamente 30 dias.

associados pesos que multiplicam o sinal transmitido e são somados linearmente fornecendo assim a informação de entrada para a função de ativação, está por sua vez irá determinar o sinal de saída (FAUSETT, 1994).

A Figura 1 representa um modelo simplificado de uma RNA com 3 entradas, uma entrada de valor constante (*bias* representado pelo b) e a função de ativação $f(y_{in})$ que determina o valor da resposta da saída y . Para se iniciar o processo de treinamento ou aprendizagem de uma RNA de forma a ser capaz de identificar padrões, aplica-se a combinação desejada de valores em suas entradas, que serão ponderadas e combinadas linearmente. A RNA soma à esta combinação um valor constante, portanto independentemente do valor de suas entradas.

Esta soma linear de combinação desejada das entradas e um valor constante ponderadas por pesos (y_{in}) torna-se o sinal de entrada da função de ativação $f(y_{in})$, o resultado então é utilizado para obter-se o valor correspondente de resposta para as entradas.

Comparada com a resposta desejada, se a diferença estiver acima de um determinado limiar, os pesos da RNA são atualizados e o processo de treinamento reinicia com subsequente combinação de entradas. O processo de treinamento é finalizado quando a diferença entre a resposta desejada e a saída da RNA retorna um valor menor que o limiar configurado (SIVANANDAM; DEEPA, 2006).

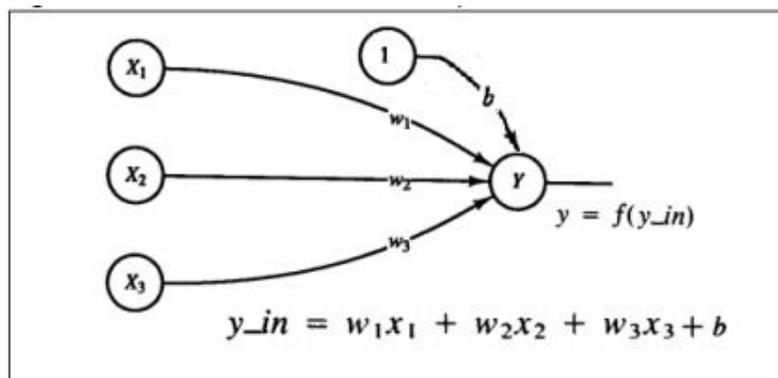


Figura 1- Uma RNA simplificada (Fonte: Adaptado de FAUSETT (1994)).

A regressão linear múltipla permite estudar os múltiplos relacionamentos entre a variável dependente (resposta de saída) e as variáveis independentes (entradas) através da combinação linear de coeficientes de regressão, dada pela equação 1 (MONTGOMERY; RUNGER, 2009):

$$Y = \beta_0 + \beta_1X_1 + \beta_2X_2 \dots \beta_kX_k + \epsilon \quad (1)$$

onde $X_1, X_2 \dots X_k$ são as k variáveis de entrada, $\beta_0, \beta_1, \beta_2 \dots \beta_k$ são os coeficientes de regressão e ϵ é a componente aleatória, denominada de resíduo, que não pode ser estimada. Para que o modelo seja válido a distribuição estatística do resíduo deve obedecer uma distribuição gaussiana de média zero e variância, além disso os resíduos devem possuir covariância zero, o que significa que devem ser independentes entre si.

Igualmente importante ao se desenvolver um modelo de previsão baseado na regressão linear é verificar se no mínimo uma das variáveis de entrada contribui significativamente para o valor da resposta, ou se a componente aleatória tem composição predominante tal que a variação das entradas tem pouco ou nenhum impacto no valor de saída. O teste de significância é dado pelas seguintes hipóteses (MONTGOMERY; RUNGER, 2009):

$$H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0$$

$$H_1: \beta_j \neq 0 \text{ para no mínimo um } j$$

Para se determinar qual hipótese é válida, considera-se H_0 verdadeira e calcula-se a sua probabilidade, denominada de *p-value*. Este valor é comparado com valores críticos que são determinados pelo nível de significância adotado. O nível de significância é definido como a probabilidade de rejeitar incorretamente a hipótese H_0 . Valores de *p-value* menores que o nível de significância determinam a rejeição da hipótese H_0 , indicando que ao menos uma das variáveis dependentes contribui para a variabilidade da variável resposta.

Outro parâmetro importante utilizado na análise de regressão linear múltipla é o coeficiente de determinação R^2 e mede a proporção da variabilidade da resposta que pode ser explicada pelo modelo de regressão, o valor de R^2 se encontra entre $[0,1]$. Quanto mais próximo do valor unitário maior a porcentagem da variabilidade da resposta explicada pelo modelo de regressão e menor a influência da componente aleatória e vice-versa (WALPOLE *et al.*, 2012).

Devido ao tipo de dados do problema em questão, é possível observar que técnicas de regressão linear com as RNA são adequadas para gerar soluções satisfatórias. Ademais, devido a sua grande habilidade de aprender, permite melhorar a capacidade de generalização dos dados em relação à outras técnicas de predição. Portanto, a principal contribuição desse trabalho deve responder a seguinte pergunta:

É possível aprimorar o uso dos recursos do manejo avícola com técnicas de *machine learning*? As pesquisas apresentadas neste trabalho vão ao encontro dessa questão, apresentando metodologias desenvolvidas para esse fim.

3. CONTRIBUIÇÕES

Em trabalhos anteriores (WIRTH *et al.*, 2013), (ENEMBECK *et al.*, 2015) e (LORENCENA, 2016) foram estudadas as principais atividades do manejo avícola bem como os cuidados para o bem-estar das aves. Nesses estudos foram destacadas as características do problema e as particularidades para a produção de aves. Além de materiais bibliográficos, como por exemplo (LANA, 2000), (COBB, 2012) e (HI-PRO, 2016) observou-se em visitas *in loco*, que o manejo avícola é realizado muitas vezes de acordo com as crenças, objetivos e desejos de cada avicultor. Avicultores com maior experiência, como aqueles com mais de 5 anos na produção de aves, usam sintomaticamente o conhecimento empírico como forma de melhorar a produção. Já os avicultores com menor experiência, são conservadores e baseiam-se na maioria das vezes em materiais bibliográficos ou manuais.

3.1 Aquisição e estrutura dos dados

Nesse projeto, os dados foram obtidos de um aviário onde o manejo foi realizado por um avicultor com bastante experiência. Dados complementares foram obtidos em materiais bibliográficos. Portanto, os dados usados nesse projeto são fidedignos para a construção de um sistema especialista de alta confiança.

A Figura 2 ilustra as etapas que compõem a contribuição deste trabalho. A figura 2a ilustra a origem dos dados. O aviário tem uma estrutura do tipo *dark house*⁴. O aviário possui a seguinte descrição: quantidade de sensores: 2, dimensões (m) (Prof. × Larg. × Alt.): 150 × 16 × 2,5, capacidade de aves: 29 mil, quantidade de comedouros: 704, quantidade de bebedouros: 2745. Na figura 2b é usado um sistema eletrônico para aquisição dos dados. Esse sistema é conectado por sensores, que são usados para informar os dados de temperatura, umidade, ventilação, quantidade de ração e água consumida. Na figura 2c os dados foram pré-processados. Nessa etapa dois conjuntos de dados foram gerados (treinamento e teste), no qual dados inconsistentes foram eliminados e dados faltantes foram adicionados com apoio da literatura (COBB, 2012) (HI-PRO, 2016). Já na figura 2d é usada uma RNA com regressão linear para a predição dos dados, discutida na seção 3.2.

⁴ *Dark house* é um tipo de tecnologia onde a luminosidade é controlada por luz artificial, devido ausência da luz natural. O objetivo é possibilitar ao avicultor melhor controle de temperatura, umidade e luminosidade.

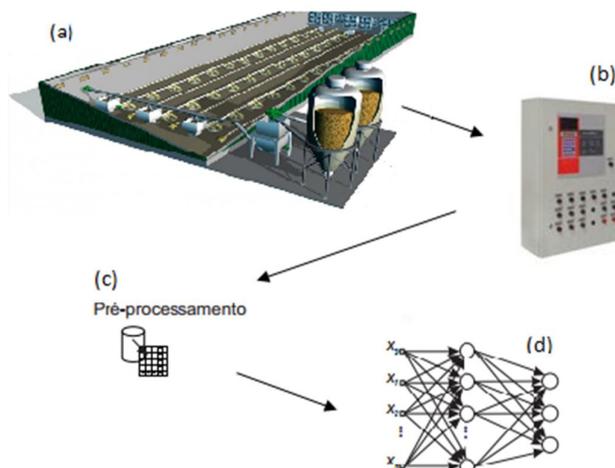


Figura 2 - Ilustração das etapas da aquisição e processamento dos dados. (a) Origem dos dados (aviário), (b) Aquisição dos dados, (c) Pré-processamento, (d) Predição.

Conforme mencionado nas Figura 2b e 2c, os dados coletados foram separados em dois conjuntos. O primeiro conjunto de dados representa a percepção do avicultor, formado pela *hora do manejo, condição climática externa do aviário, tamanho da área para as aves, temperatura externa do aviário (C°), e temperatura desejada (C°)*. A Tabela 1 mostra os dados de manejo de um dia.

<i>Hora do manejo</i>	<i>Condição climática externa do aviário</i>	<i>Tamanho da área para as aves</i>	<i>Temperatura externa do aviário (C°)</i>	<i>Temperatura desejada (C°)</i>
1	Nuvens dispersas	60	21	30
2	Nuvens dispersas	60	21	30
3	Muito nublado	60	22	30
4	Céu limpo	60	23	30
5	Nuvens dispersas	60	21	30
6	Nuvens dispersas	60	20	30
7	Muito nublado	60	20	30
8	Chuva fraca	60	21	30
9	Chuva fraca	60	22	30
10	Muito nublado	60	23	30
11	Muito nublado	60	25	30
12	Muito nublado	60	26	30
13	Muito nublado	60	26	30
14	Chuva fraca	60	25	30
15	Chuva fraca	60	27	30
16	Parcialmente nublado	60	28	30
17	Céu limpo	60	30	30
18	Céu limpo	60	28	30
19	Céu limpo	60	27	30
20	Muito nublado	60	26	30
21	Parcialmente nublado	60	23	30

22	Nuvens dispersas	60	22	30
23	Céu limpo	60	22	30
24	Céu limpo	60	21	30

Tabela 1 – Conjunto de dados referente a percepção do avicultor.

O atributo *hora do manejo* indica o momento que os dados foram obtidos. A hora faz inferência a temperatura externa e a condição do ambiente. Horários próximos às 12h indicam alta temperatura e umidade baixa do ar, enquanto horários após às 20h indicam o oposto. O atributo *tamanho da área para as aves* indica o espaço de movimentação em metros⁵. Esse espaço limita o movimento das aves, fazendo que gastem menos energia. Esse espaço é ajustado de acordo com o seu crescimento. O atributo *temperatura interna do aviário (C°)* é usado para ajustar o atributo *temperatura desejada (C°)*. Esses atributos indicam o conforto térmico para as aves, ou seja, condição relacionada ao bem-estar. Condições adequadas implicam na melhor alimentação, favorecendo a conversão alimentar. Já o atributo *condição climática externa do aviário* é usado para renovação do ar. Essa condição interfere na temperatura e umidade interna do aviário. Por exemplo, umidade externa alta e temperatura interna elevada, aumenta a sensação de sufocamento para as aves, indicando a necessidade do uso da ventilação.

Os valores que esses atributos podem assumir são: *hora do manejo* {1,...,24}; *tamanho da área para as aves* {60,...,150}; *temperatura externa do aviário (C°)* {21,...,32}; *temperatura desejada (C°)* {26,...,31}; *condição climática externa do aviário* {céu limpo, muito nublado, bancos de nevoeiro, céu encoberto, chuva, chuva fraca, neblina, nevoeiro, nevoeiro fraco, nuvens dispersas, parcialmente nublado, trovoadas fracas, chuva, sol}.

Já o segundo conjunto de dados representa a atuação do avicultor, formado pela *temperatura máxima, temperatura mínima, aquecer a partir de (C°), tempo de ventilação em segundos e quantidade de exaustores ligados*. A Tabela 2 mostra os valores empregados pelo avicultor. Estes valores representam o manejo avícola, e são realizados com base na Tabela 1.

Os atributos *temperatura máxima* e *temperatura mínima* implicam no conforto térmico. Valores acima da temperatura máxima e abaixo da temperatura mínima afetam a conversão alimentar, podendo causar danos à saúde das aves. Os atributos *aquecer a partir de (C°)* e *aquecer até (C°)* são usados para manter o aquecimento do aviário. Os valores de referência foram obtidos na literatura (COBB, 2012). Os atributos *tempo de ventilação em segundos* e *quantidade de exaustores ligados* são usados para garantir a sensação térmica ideal para as aves.

⁵ A área de movimentação das aves é em relação a maior dimensão do aviário, nesse caso comprimento.

O atributo *quantidade de exaustores ligados* faz a renovação do ar, mantendo a temperatura e umidade nos valores desejáveis.

Os valores que esses atributos podem assumir são: *temperatura máxima* {25,...,35}; *temperatura mínima* {23,...,36}; *aquecer a partir de (C°)* {25,...,31}; *tempo de ventilação em segundos* {64,...,140}; *quantidade de exaustores ligados* {0,...,9}.

<i>Temperatura máxima (C°)</i>	<i>Temperatura mínima (C°)</i>	<i>Aquecer a partir de (C°)</i>	<i>Aquecer até (C°)</i>	<i>Tempo de ventilação em segundos</i>	<i>Quantidade de exaustores ligados</i>
34	28	29	31	140	1
33	27	28	30	130	1
32	26	27	29	130	1

Tabela 2 - Conjunto de dados referente a atuação do avicultor.

Na Tabela 3 é mostrado um exemplo usando os conjuntos. Os dados expostos refletem um caso real de manejo realizado.

Conjunto 1 (Percepção)		Conjunto 2 (Atuação)	
Hora do manejo	13h	Temperatura máxima (C°)	34
Condição climática externa do aviário	Nuvens dispersas	Temperatura mínima (C°)	28
Tamanho da área para as aves	60	Aquecer a partir de (C°)	29
Temperatura externa	21	Aquecer até (C°)	31
Temperatura desejada	31	Tempo de ventilação em segundos	140
		Quantidade de exaustores ligados	1

Tabela 3 - Exemplo de um caso real.

3.2 Aplicação da abordagem proposta

Os conjuntos 1 e 2 foram usados no treinamento da RNA, divididos em conjuntos de treinamento e teste. O conjunto de treinamento é usado para aprendizagem da RNA e o conjunto de teste para verificar sua generalização.

Para dividir o conjunto de dados em treinamento e teste, foram empregadas as técnicas de validação cruzada *holdout* (KOHAVI, 1995). Essa técnica é utilizada para avaliar a

capacidade de generalização dos algoritmos de aprendizagem de máquina a partir dos conjuntos de dados de treinamento e teste.

Na técnica *holdout*, o conjunto de treinamento é dividido em dois subconjuntos: um para treinamento e outro para teste. Os conjuntos são mutuamente exclusivos e, na abordagem proposta, os dados foram divididos em 90% para treinamento e 10% para teste. Todos os testes realizados com a RNA foram utilizando validação cruzada com *holdout*.

Para o treinamento da RNA foi usada uma rede multicamadas treinada com o algoritmo *backpropagation*, usando a função de transferência sigmoide nas camadas ocultas (1^a., 2^a. e 3^a.) e uma função de transferência linear na camada de saída. Como função de ativação foi utilizada a implementação do algoritmo regressão bayesiana no software *Matlab*.

A RNA foi estruturada com 5 neurônios na camada de entrada. Nas camadas do meio foram usados 20, 10 e 20 neurônios respectivamente. Na camada de saída, 6 neurônios irão representar os atributos de predição. A Figura 3 ilustra a arquitetura da RNA utilizada.

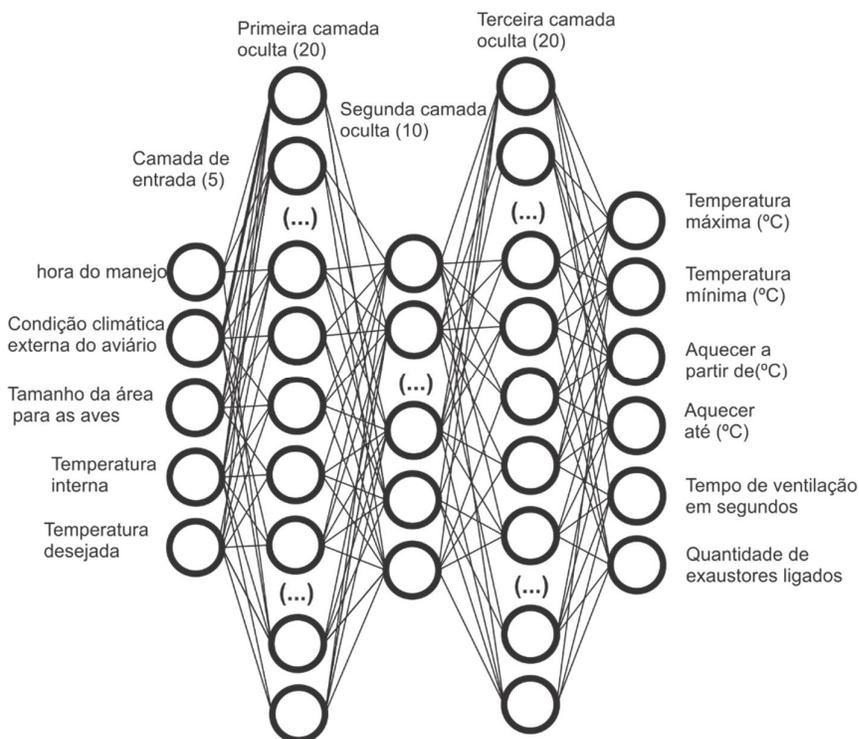


Figura 3 - Representação da RNA utilizada neste trabalho.

4. RESULTADOS EXPERIMENTAIS

A RNA foi treinada até o ciclo (época) 500, quando a taxa de erro do conjunto de teste começou a aumentar. Nesse ponto, o treinamento foi interrompido, pois o erro quadrático médio estabilizou no valor igual ao melhor resultado.

No treinamento da RNA os parâmetros *taxa de aprendizagem* e *termo momentum* foram ajustados. A *taxa de aprendizagem* determina a dimensão do ajuste dos pesos a cada iteração durante o treinamento da RNA. Já o *termo momentum* é utilizado para aumentar a velocidade de treinamento da rede. Diferentes valores têm sido utilizados para esses termos (REFENES *et al.*, 1994; ATTOH-OKINE, 1999; KUAN; WHITE, 1994). Para a *taxa de aprendizagem* recomenda-se atribuir $0,2 \geq \eta \leq 0,8$ enquanto que para o *termo momentum* $0,3 \geq \alpha \leq 0,7$, podendo esses valores serem alterados de acordo com o domínio do problema. Os valores definidos para a *taxa de aprendizagem* e *termo momentum* foram, respectivamente, 0,5 e 0,7, os quais foram utilizados durante todos os experimentos. Esses valores foram obtidos após simulações, onde foi levado em consideração a quantidade de ciclos de treinamento e capacidade de generalização do classificador. Quando atribuídos valores mais próximos de 1 para a *taxa de aprendizagem* e *termo momentum* o treinamento ocorreu mais rapidamente, porém a capacidade de generalização do classificador diminuiu. Então, esses valores foram decrescidos até encontrar um ponto em que a capacidade de generalização não sofresse alteração.

Foram realizados experimentos com os algoritmos *Levenber Marquardt* (LEVENBER, 1944) (MARQUARDT, 1963) e *Scaled Conjugate Gradiente* (MOLLER, 1991) porém o que apresentou melhor resultado foi o *Bayesian Regularization* (MACKAY, 1992) (FORESEE, HAGAN, 1997). Os resultados dos experimentos realizados com cada algoritmo são apresentados na Tabela 4 **Erro! Fonte de referência não encontrada..**

<i>Algoritmos</i>	Valor de R obtido com o conjunto de treinamento	Valor de R obtido com o conjunto de teste	Número de erros por instância					
			1	2	3	4	5	10
<i>Levenber Marquardt</i>	0,99993	0,99993	11	3	1	0	0	0
<i>Scaled Conjugate Gradiente</i>	0,99968	0,99951	35	6	3	1	2	1
<i>Bayesian Regularization</i>	0,99999	0,99998	0	1	0	0	0	0

Tabela 4 - Comparativo dos algoritmos testados.

O valor de *R* é uma indicação da relação entre as saídas e os alvos (*target*). Quanto mais próximo de 1 o valor de *R*, mais linear os valores de saídas e alvos. Na tabela 4 são apresentados

os valores de R obtidos com o conjunto de treinamento e teste, bem como a quantidade de erros e a quantidade de instâncias correspondentes do conjunto de teste. É possível observar que o algoritmo *Bayesian Regularization* gerou apenas 2 erros para uma única instância. Esse pequeno número de instância e erros é devido aos valores de R estarem muito próximos de 1. Portanto, a RNA com o algoritmo *Bayesian Regularization* apresentou o menor número de erros comparado aos demais.

Na Figura é apresentado o gráfico de dispersão. A linha tracejada representa o resultado ótimo. A linha contínua representa a regressão linear de melhor ajuste entre as variáveis de saída, que são os valores estimados pela RNA, e os alvos que são os valores reais. Os círculos indicam a disposição dos dados. O eixo X do gráfico representa os dados fornecidos pela rede ($Output \sim 1 * Target + 0,00061$) e o eixo Y o valor real ($Target$).

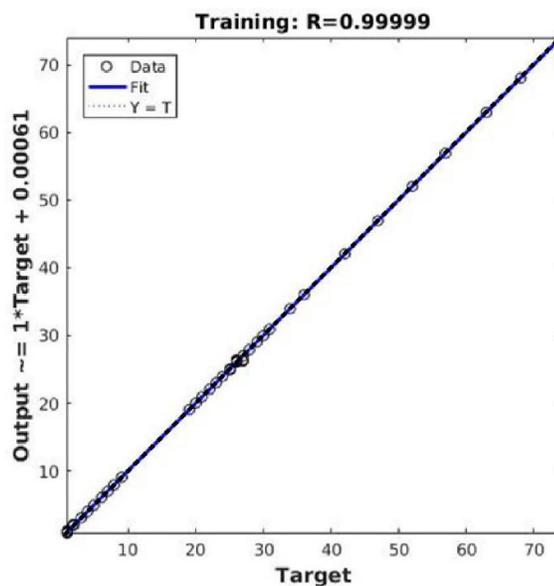


Figura 4 - Gráfico de dispersão.

Os experimentos com a RNA avaliaram 101 instâncias, apresentando um percentual de acerto de 97%. As instâncias previstas incorretamente (duas) foram submetidas para análise, na intenção de verificar o impacto em termos de produtividade e bem-estar das aves. As instâncias analisadas apresentaram valores diferentes no atributo *temperatura mínima* para o resultado desejado. A análise mostrou o erro em $1C^{\circ}$ para menos. Submetida ao especialista humano, foi concluído que o manejo usando esse valor não afeta o lote em termos de produtividade (conversão alimentar) e a saúde das aves.

5. CONCLUSÕES E DISCUSSÕES FINAIS

Neste trabalho foi mostrado como técnicas de aprendizagem de máquina podem ser empregadas para o aprimoramento das atividades do manejo avícola. O manejo avícola consiste no controle de recursos como água, ração, temperatura, umidade, ventilação e outros. Foi introduzido um modelo de aprendizagem utilizando regressão linear com uma RNA.

Foram avaliados diferentes algoritmos para a construção da RNA. Por meio desses experimentos, verificou-se que o algoritmo *bayesian regularization* apresentou os melhores resultados, com acerto de 97% dos casos. As instâncias preditas incorretamente foram analisadas por um especialista do domínio do problema. Concluiu-se que os valores indicados não causam danos à saúde das aves bem como impacto na conversão alimentar.

Em um trabalho anterior (WIRTH *et al.*, 2013), foi utilizada uma técnica de classificação usando árvores de decisão, na intenção de prover um sistema computacional com a capacidade de mostrar ao avicultor o melhor manejo. No entanto, esse tipo de abordagem gera uma grande quantidade de classificações. Como uma classificação é formada por vários atributos, a variação de um valor gera uma nova classe, o que torna o classificador impreciso, limitando assim a técnica proposta. Já no trabalho de (RIBEIRO *et al.*, 2015), foi proposta uma abordagem que usa Raciocínio Baseado em Casos (RBC). Os autores usaram o algoritmo *K-nn* para geração das regras para classificação, utilizando situações já ocorridas a priori. Apesar dos ganhos com essa abordagem, a técnica é limitada devido a necessidade de existir previamente um manejo com características similares para que seja possível utilizar a técnica de RBC.

Neste trabalho, foi proposto uma forma de superar essas limitações, utilizando uma técnica de regressão linear por meio de uma RNA. Dessa forma, foi possível estimar valores sem a necessidade de uma base histórica com todos os manejos, o que na prática é inviável, devido a quantidade de combinações dos valores de cada recurso disponível.

Pesquisas futuras incluem: (i) avaliação do desempenho da RNA com novos dados, como por exemplo, dados oriundos de uma rede de sensores. (ii) testar a proposta em aviários com novas tecnologias, como por exemplo, a abordagem inspirada na Teoria de Controle Supervisório para o controle automático da temperatura e da umidade (LORENCENA *et al.*, 2016); (iii) incluir dados dos manejos de avicultores com pouca experiência, avaliando o impacto da conversão alimentar bem como o uso de outros recursos; e (vi) integrar a proposta a um sistema do tipo SCADA.

6. REFERÊNCIAS

- ABPA, **Relatório anual 2016**, disponível em: < http://abpa-br.com.br/storage/files/versao_final_para_envio_digital_1925a_final_abpa_relatorio_anual_2016_portugues_web1.pdf >, acesso em 20 dez. 2016.
- ATTOH-OKINE, N. O. Analysis of learning rate and momentum term in backpropagation neural network algorithm trained to predict pavement performance. *Advances in Engineering Software*, Elsevier BV, v. 30, n. 4, p. 291–302, 1999.
- AU, T.-C., ZHANG, S., STONE, P. (2014). *Semiautonomous intersection management*. In Proceedings of the 2014 International Conference on Autonomous Agents and Multi-agent Systems, AAMAS '14, pages 1451–1452.
- BACHRACH, Y., SAVANI, R., and SHAH, N. (2014). *Cooperative max games and agent failures*. In Proceedings of the 2014 International Conference on Autonomous Agents and Multi-Agent Systems, AAMAS '14, pages 29–36.
- COBB, *Broiler management guide*, disponível em: < <http://images.agri-profocus.nl/upload/cobb-broiler-management-guide-20121469468173.pdf> >, acesso em 20 dez. 2016.
- COBO, L. C., ISBELL, C. L., and THOMAZ, A. L. (2013). *Object focused q-learning for autonomous agents*. In Proceedings of the 2013 International Conference on Autonomous Agents and Multi-Agent Systems, AAMAS '13, pages 1061–1068.
- FAUSETT L. **Fundamentals of neural networks architectures, algorithms and applications**. Prentice Hall, 1994.
- FORESEE and HAGAN, *Proceedings of the International Joint Conference on Neural Networks*, June, 1997
- HI-PRO, *Broiler management e feeding guide*, disponível em: < <http://images.agri-profocus.nl/upload/cobb-broiler-management-guide-20121469468173.pdf> >, acesso em 20 dez. 2016.
- JIANG, S., ZHANG, J., and ONG, Y.-S. (2014). **A pheromone-based traffic management model for vehicle re-routing and traffic light control**. In Proceedings of the 2014 International Conference on Autonomous Agents and Multi-Agent Systems, AAMAS '14, pages 1479–1480.
- KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: **Proceedings of the 14th International Joint Conference on Artificial Intelligence - Volume 2**. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1995. (IJCAI'95), p. 1137–1143.
- KUAN, C.-M.; WHITE, H. Artificial neural networks: an econometric perspective. **Econometric Reviews**, Informa UK Limited, v. 13, n. 1, p. 1–91, Jan 1994. ISSN 1532-4168.
- LANA, G. R. Q. **Avicultura**. Campinas: Rural, 2000.
- LEVENBERG K. . **A Method for the Solution of Certain Non-Linear Problems in Least Squares**. *Quarterly Journal of Applied Mathematics*, Vol. II, No. 2. (1944), pp. 164-168
- LORENCENA, M. C.; TEIXEIRA, M.; SILVA, A. L. ; RIBEIRO, R. ; BARBOSA, M. A. C. . **Contribuições ao Manejo Avícola Utilizando Técnicas de Controle Supervisório**. In:

Congresso INDUSCON 2016 - 12th IEEE/IAS International Conference on Industry Applications, 2016, Curitiba – PR.

MACKAY, **Neural Computation**, Vol. 4, No. 3, 1992, pp. 415–447

MARQUARDT, D. W..(1963). **An Algorithm for Least-Squares Estimation of Nonlinear Parameters**. *SIAM Journal on Applied Mathematics* [S.l.: s.n.]11(2): 431–441.

MATHWORKS, **Analyze Neural Network Performance After Training**. Disponível em: <<https://www.mathworks.com/help/nnet/ug/analyze-neural-network-performance-after-training.html>>, acesso em 1 fev. 2016.

MOLLER, M. F.. **A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning** 1991

MONTGOMERY, D. C.; RUNGER, G. C. **Estatística aplicada e probabilidade para Engenheiros**. 4. ed., Editora LTC, 2009.

REFENES, A. N.; ZAPRANIS, A.; FRANCIS, G. **Stock performance modeling using neural networks: A comparative study with regression models**. *Neural Networks*, Elsevier BV, v. 7,n. 2, p. 375–388, Jan 1994.

RIBEIRO, R. and ENEMBRECK, F. (2013). **A sociologically inspired heuristic for optimization algorithms: A case study on ant systems**. *Expert Systems With Applications*, 40(5):1814–1826.

RIBEIRO, R., F., BARBOSA, M. A. C., BORGES, A. P., DORDAL, O. B., KOERICH, A. L., ENEMBRECK, F. (2012). **Unified algorithm to improve reinforcement learning in dynamic environments - an instance-based approach**. In *International Conference on Enterprise Information Systems, ICEIS '12*, pages 229–238.

RIBEIRO, R., RONSZCKA, A. F., BARBOSA, M. A. C., F., ENEMBRECK, F. (2013). **Updating strategies of policies for coordinating agent e swarm in dynamic environments**. In *International Conference on Enterprise Information Systems, ICEIS '13*, pages 345–356.

RIBEIRO, R., TEIXEIRA, M., L. WIRTH, A., P. BORGES, A., ENEMBRECK, F., **A Learning Model for Intelligent Agents Applied to Poultry Farming**. 17th International Conference on Enterprise Information Systems, 2015, Barcelona. *Proceedings of the 17th International Conference on Enterprise Information Systems, 2015*. p. 495.

SIVANANDAM, S. N.; DEEPA, S. N. **Introduction to neural networks using Matlab 6.0**. Tata McGraw-Hill Education, 2006.

WALPOLE, R. E *et al.* **Probability and statistics for engineers and scientists**. 9 ed., Prentice Hall, 2012.

WIRTH, A. L.; MOCELIN, R.; RIBEIRO, R. **Técnicas de aprendizagem de máquina para auxiliar avicultores nas atividades de manejo avícola**. SECOMPB - Primeira Semana Acadêmica de Computação, 2013, Pato Branco. I SECOMPB, 2013.