

GESTÃO DA PRODUÇÃO DE FRANGOS DE CORTE POR MEIO DE REDES NEURAIS ARTIFICIAIS

T.C. PINHEIRO¹, J.A.A. SANTOS², L.A. PASA³
Universidade Tecnológica Federal do Paraná
tascarpin@yahoo.com.br¹

Submetido 30/09/2019 – Aceito 18/02/2020

DOI: 10.15628/holos.2020.9043

RESUMO

Atualmente, o ambiente globalizado e altamente competitivo impõe as empresas produtoras de frango dois grandes desafios: a otimização de recursos e a redução dos custos. Neste contexto, este trabalho tem por objetivo utilizar redes neurais artificiais e regressão linear múltipla para análise e previsão de variáveis produtivas de frangos de corte de uma agroindústria paranaense. Analisa-se também, a aplicabilidade de redes neurais recorrentes na previsão do preço do quilo do frango congelado e resfriado. A base de dados disponibilizada pela empresa apresenta um histórico de movimentação de 2 anos, contendo as principais variáveis de produção, para 4650 lotes de aves das

linhagens *Coob*, *Coob Fast* e *Coob Slow*. Na análise de aplicabilidade de redes neurais, recorrentes utilizou-se um banco de dados de 11 anos fornecido pelo Centro de Estudos Avançado de Economia Aplicada (CEPEA). Os resultados obtidos mostram que os modelos de previsão fornecem estimativas confiáveis para as variáveis de resposta: Peso Médio e Índice de Eficiência Produtiva e demonstram a eficácia das previsões, da rede recorrente LSTM, para o preço do quilo do frango congelado e resfriado, para um horizonte de curto prazo.

PALAVRAS-CHAVE: redes neurais artificiais, frangos de corte, agroindústria.

MANAGEMENT OF THE PRODUCTION OF BROILER CHICKENS THROUGH ARTIFICIAL NEURAL

ABSTRACT

Today's globalized and highly competitive environment imposes chicken producers two major challenges: resource optimization and cost reduction. In this context, this work aims to use artificial neural network models and multiple linear regression for analysis and prediction of broiler productive variables of an agribusiness of Paraná. The applicability of recurrent neural networks to predict the price of kilo of frozen and chilled chicken is also analyzed. The database provided by the company has a 2-year history of movement, containing the main

production variables, for 4500 batches of *Coob*, *Coob Fast* and *Coob Slow* strains. In the analysis of the applicability of recurrent neural networks we used a 11-year database provided by the Center for Advanced Studies in Applied Economics (CEPEA). The results show that the forecast models provide reliable estimates for the response variables: Average Weight and Productive Efficiency Ratio and demonstrate the effectiveness of the recurring LSTM predictions for the price of kilo of frozen and chilled chicken for a short term horizon.

KEYWORDS: artificial neural network, broiler chickens, agroindustry.

1 INTRODUÇÃO

Atualmente, a avicultura é uma atividade econômica internacionalizada e uniforme, sem fronteiras geográficas de tecnologia. No Brasil, está presente em todas as regiões e tem gerado um efeito positivo na economia da maioria dos estados (UBA, 2008; JÚNIOR et al., 2009).

A avicultura é um dos principais componentes do agronegócio brasileiro. Seu desenvolvimento pode ser considerado como o símbolo do crescimento e modernização do setor. Atualmente, em menos de 50 dias tem-se um lote de frangos pronto para o abate. Segundo a ABPA (2018), há perspectiva de que o país produza em 2019 aproximadamente 11,5 milhões de toneladas de frango. Desse montante, 3,7 milhões devem ser exportados. O setor espera um aumento no consumo em torno de 3% nos próximos anos.

A demanda crescente por carne de frango motiva a necessidade de planejamento da produção de frangos de corte e de ferramentas de tomada de decisão. A tomada de decisão, no meio industrial, é um importante fator para obtenção de vantagens competitivas (AZARIAS, 2009). Nesse sentido, as Redes Neurais Artificiais (RNA) podem ser utilizadas como ferramentas de apoio no processo de tomada de decisão. São ferramentas de grande importância em um sistema de planejamento, pois direcionam a melhor forma de aproveitar todos os recursos disponíveis pela empresa.

Diversos trabalhos utilizaram redes neurais artificiais na gestão da produção de frangos de corte. Dentre eles podem-se citar os trabalhos de: Bastiani *et al.* (2018) que estudou a aplicação de algoritmos de mineração de dados na gestão da produção de frangos de corte por meio do software WEKA; Johansen *et al.* (2019) que realizou a previsão do peso de abate de frangos de corte utilizando modelos dinâmicos de redes neurais e Amrael *et al.* (2017) que analisou o peso de frangos de corte com base em redes neurais artificiais e visão de máquina. Já a análise do preço do frango resfriado, no atacado da grande São Paulo, foi realizada por Campos (2006), utilizando um modelo auto-regressivo de médias móveis (ARIMA).

Nessa perspectiva, assinala-se que redes neurais artificiais estão sendo aplicadas em várias áreas, tais como Medicina, Engenharia, Física, entre outras. Podem ser aplicadas em problemas de regressão, classificação e compactação de dados. As redes neurais artificiais processam os dados de maneira muito parecida ao cérebro humano. Utilizam, no processamento de informações, o princípio de organização de neurônios do cérebro. Portanto, pode-se considerar as redes neurais artificiais como um esquema de processamento capaz de armazenar conhecimento e disponibilizá-lo para determinada aplicação (HAYKINS, 2005). As redes neurais são capazes de memorizar, analisar e processar um grande número de dados obtidos de um experimento. É uma técnica de modelagem que pode resolver muitos problemas complexos (SEBASTIAN, 2016).

Neste contexto, este trabalho tem por objetivo utilizar redes neurais artificiais *Multilayer Perceptron* (MLP) e Regressão Linear Múltipla (LR) para análise e previsão de variáveis produtivas de frangos de corte. Analisa-se também, neste trabalho, a aplicabilidade de redes neurais recorrentes (LSTM) na previsão do preço do quilo do frango (R\$/kg), congelado e resfriado, negociado no atacado da região da grande São Paulo. Observa-se que as oscilações do preço do

frango de corte influenciam diretamente no setor primário. O setor primário é o setor envolvido com a produção de matérias-primas. Segundo Piacenti (2007), na produção de qualquer bem, em especial no setor primário, a decisão do uso de insumos deve ser feita antes da produção. Por isso o produtor tem que basear suas decisões em preços futuros.

2 MATERIAIS E MÉTODOS

A empresa, foco deste estudo, está situada no estado do Paraná, sendo de grande porte e atuação no ramo agroindustrial, em especial na produção de frangos de corte. Possui um frigorífico que realiza o abate diário de aproximadamente 300 mil aves. Atualmente, conta com 6.794 associados e 2.660 funcionários.

A empresa mede a eficiência produtiva do avicultor por meio do Índice de Eficiência Produtiva (IEP). A remuneração do produtor também está condicionada ao seu desempenho mensurado através do IEP (SOBRINHO, 2010). O IEP leva em conta a Conversão Alimentar, o Ganho de Peso Diário e a Viabilidade do lote. O IEP é obtido por meio da Equação 1:

$$IEP = \frac{\text{Ganhode Peso Diário (GPD)} \times \text{Viabilidade (VIAB)}}{\text{Conversão Alimentar (CA)}} \times 100 \quad (1)$$

onde:

$$\text{Peso Médio (PM)} = \frac{\text{Peso total do lote}}{\text{Aves Abatidas (ABAT)}} \quad (2)$$

$$\text{Ganho de Peso Diário (GPD)} = \frac{\text{Peso Médio (PM)}}{\text{Idade (ID)}} \quad (3)$$

$$\text{Conversão Alimentar (CA)} = \frac{\text{Consumo total de ração (CONS)}}{\text{Peso total do lote}} \quad (4)$$

$$\text{Viabilidade (VIAB)} = \frac{\text{Aves Abatidas (ABAT)}}{\text{Aves Alocadas (ALOC)}} \quad (5)$$

Além do IEP, o Peso Médio (PM) é outro índice monitorado pela empresa. Este índice é também importante na adequação dos equipamentos automatizados de uma agroindústria de abate de frangos de corte. Portanto, as empresas avícolas buscam uma uniformidade do peso do produto, já que uma baixa uniformidade prejudica o desempenho do processo, a integridade do produto, o comprimento das especificações dos clientes e o aumento de descarte das peças (BASTIANI et al., 2018).

2.1 Tratamento de dados

Inicialmente, realizou-se a limpeza dos dados fornecidos pela empresa. A limpeza dos dados visa detectar e remover anomalias presentes nos dados com o objetivo de aumentar e melhorar

sua qualidade. O conjunto de dados fornecido pela empresa continha valores nulos e redundantes. Estes valores foram manualmente retirados do conjunto de dados.

Ao final desta etapa, obteve-se um banco de dados, com 4650 lotes de aves, unificado e livre de inconsistências, contendo informações sobre os seguintes atributos: Ganho de Peso Diário (GPD), Consumo (CONS), Idade (ID), Conversão Alimentar (CA), Aves Alocadas (ALOC), Aves Abatidas (ABAT), Linhagem (LIN) e o Peso Médio (PM).

Para previsão do preço do quilo do frango congelado e resfriado (R\$/kg), utilizaram-se duas bases de dados de 11 anos (2008-2019), 132 meses, obtidas do Centro de Estudos Avançados em Economia (CEPEA, 2019). As séries históricas, do preço do frango congelado e resfriado, são apresentadas na Figura 1.




Figura 1: Séries com os preços do quilo do frango congelado e resfriado.

Observa-se que os dados obtidos, do preço do quilo de frango (R\$/kg) congelado e resfriado, da base de dados do CEPEA já estavam limpos e sem a presença de outliers (CEPEA, 2019).

A normalização dos dados, para o intervalo $[-1,1]$, foi realizada por meio da função `MinMaxScaler()` da biblioteca `Scikit-learn` do Python.

2.2 Algoritmos de Mineração de Dados

Neste trabalho, foram implementados, na linguagem Python, três algoritmos de mineração de dados:

Regressão Linear Múltipla (LR): Modelos baseados em regressão linear são muito utilizados em mineração de dados para realizar previsões. As regressões são chamadas de lineares quando a

relação entre as variáveis preditoras e a resposta segue um comportamento linear. Esta relação pode ser descrita como uma função linear: $y = w_0 + w_1a_1 + w_2a_2 + \dots + w_ka_k$. Onde po é a classe, $a_1, a_{12} + \dots + a_k$ são os valores dos atributos e $w_1, w_{12} + \dots + w_k$ são os pesos. Os pesos são calculados através dos dados de treinamento (HEIDARI, 2019; SING et al., 2017).

Multilayer Perception (MLP): As redes MLPs representam uma classe de redes neurais muito utilizadas em mineração de dados. A rede é composta por uma camada de entrada, uma ou mais camadas ocultas de unidades de processamento e uma camada de saída. Por padrão, o seu treinamento é supervisionado e utiliza o algoritmo *backpropagation*. As redes MLPs podem realizar tanto regressão quanto classificação (SANTOS et al., 2013; SEBASTIAN, 2016).

Redes Neurais Recorrentes (RNN): Segundo Braga (2019), a computação convencional não realiza, de forma satisfatória, tarefas de reconhecimento de padrão dinâmico, caso das séries temporais. Portanto, necessita-se de estruturas que sejam capazes de representar o tempo e apresentar memória. Dentre essas estruturas tem-se as Redes Neurais Recorrentes (RNNs). A rede *Long Short Term Memory (LSTM)*, dentre as redes recorrentes, foi a que mais teve êxito, porque é capaz de aprender dependências de longo prazo, o que não é possível com redes neurais recorrentes tradicionais (ZAO, 2017). Tal rede se apresenta como uma boa opção para projeção de variáveis que envolvam séries temporais, devido as suas características de acumular memória e capturar a estrutura temporal das variáveis. Este fato motivou o desenvolvimento de uma aplicação do modelo LSTM para análise dos preços do quilo do frango de corte.

2.3 Recursos

Os algoritmos utilizados, neste trabalho, foram implementados com o suporte do *Jupyter Notebook* e com a linguagem de programação Python. As bibliotecas de aprendizado de máquina: *Scikit-learn* e *keras* são também utilizadas. *Scikit-learn* é uma biblioteca de aprendizado de máquina, para a linguagem Python, que inclui vários algoritmos de classificação, regressão e agrupamento. O *framework* de *Deep Learning Keras*, proporciona ferramentas para construção e treinamento de redes neurais de alto nível.

2.4 Método de fragmentação

Para criar os subconjuntos de dados, de treinamento e teste, foram usados 4500 lotes do banco de dados da empresa. Sendo 1500 da linhagem *Coob* (CB), 1500 da linhagem *Coob Fast* (CF) e 1500 da linhagem *Coob Slow* (CS). Neste trabalho, para a fragmentação dos dados (divisão dos dados em treinamento e teste) utilizou-se o método *Cross-validation* (Validação cruzada). Nesta técnica, os dados são separados em n partições aproximadamente iguais e cada uma delas é utilizada somente uma vez para teste, enquanto as demais são utilizadas para o treinamento (WITTEN; FRANK, 2005). Para o conjunto de dados de validação, foram utilizados 150 lotes do banco de dados da empresa.

Os parâmetros referentes ao número de camadas ocultas, o número de neurônios da camada oculta, o número de épocas, funções de ativação, entre outros, foram alterados empiricamente com a intenção de identificar os modelos com melhores resultados.

2.5 Métricas

Neste trabalho, os modelos obtidos foram avaliados pelas seguintes métricas (CANKURT; SUBASI, 2015):

Coefficiente de Correlação: Mede o grau de associação linear entre os dados previstos e observados.

Erro Médio Quadrático (MSE): é uma forma de avaliar a diferença entre um estimador e verdadeiro valor da quantidade estimada.

Raiz Quadrada do Erro Médio Quadrático (RMSE): Raiz do erro médio quadrático da diferença entre a predição e o valor real.

Erro Médio Absoluto (MAE): Como o RMSE, o MAE possui dimensão igual à dimensão dos valores observados e preditos. Seu valor representa o desvio médio entre observado e predito. Comparando o RMSE e o MAE, o primeiro dá um peso maior para desvios grandes (pois são elevados ao quadrado), enquanto o MAE dá um peso igual a todos os desvios.

3 RESULTADOS E DISCUSSÃO

Inicialmente, neste trabalho, realizou-se uma análise descritiva dos dados fornecidos pela agroindústria para as linhagens *Coob*, *Coob Fast* e *Coob Slow* (Tabela 1).

Tabela 1: Análise descritiva do conjunto de dados fornecido pela Cooperativa.

Variável	Lotes	Média	Mínimo	Máximo	Desvio Padrão	Coefficiente de Variação
CB						
ALOC	1650	16400,3	7300	18700	2161,98	13,183
ABAT		15774,3	6896	18644	2074,22	13,149
PM		2,81	2,378	3,26	0,165	5,872
ID		45,38	42	51	1,556	3,429
GPD		61,88	54,15	69,61	2,86	4,622
CA		1,65	1,518	1,79	0,051	3,091
CONS		4,63	3,867	5,48	0,301	6,501
CF						
ALOC	1650	18573,9	7400	31100	2729,735	14,697
ABAT		17967,8	6912	30440	2654,333	14,773
PM		2,82	2,408	3,25	0,15	5,319
ID		45,66	42	50	1,214	2,659
GPD		61,65	54,44	69,33	2,699	4,378
CA		1,66	1,523	1,79	0,049	2,952
CONS		4,66	3,879	5,47	0,271	5,815
CS						
ALOC	1650	16395,4	7500	18700	2103,52	12,830
ABAT		15852,6	6962	18405	2042,55	12,885
PM		2,84	2,401	3,25	0,153	5,387

ID	45,68	42	49	1,291	2,826
GPD	62,21	54,13	69,73	2,703	4,345
CA	1,65	1,518	1,79	0,05	3,030
CONS	4,72	9,897	5,47	0,276	5,847

Observou-se dos dados, apresentados na Tabela 1, os seguintes pesos médios: 2,81kg para a linhagem CB, 2,82kg para a linhagem CF e 2,84kg para a linhagem CS. Pesos muito próximos para as três linhagens. Por meio da Equação 1, e dados obtidos da Tabela 1, obteve-se um IEP de 361,59 para a Linhagem CB, 360,93 para CF e 363,08 para a CS.

Observa-se também, da Tabela 1, que os dados apresentam bons coeficientes de variação. De acordo com Pimentel (2000), se o coeficiente de variação for inferior a 10% tem-se um coeficiente de variação baixo, de 10 a 20% médio, de 20 a 30% alto e acima de 30% muito alto.

3.1 Seleção de atributos

A correlação é uma técnica popular para selecionar atributos relevantes em um banco de dados. Nessa técnica, pode-se calcular o grau de correlação entre cada atributo e a variável de saída e utilizar, do banco de dados, somente os atributos que tem uma correlação positiva ou negativa de moderada a alta (próxima a -1 ou 1) e retirar os atributos com baixa correlação (próxima a zero) (BASTIANI et al., 2018). Na Tabela 2, apresentam-se os resultados obtidos para as variáveis de resposta: Índice de Eficiência Produtiva e Peso Médio.

Tabela 2: Classificação dos atributos por correlação.

Filtro de classificação por correlação			
PM		IEP	
Classificação	Atributos	Classificação	Atributos
0,872864	CONS	0,847301	GPD
0,843494	GPD	0,474820	VIAB
0,597276	ID	0,185322	CONS
0,088739	LIN	0,037080	AB
-0,035639	AB	-0,021565	AL
-0,046905	AL	0,024706	LIN
-0,072381	CA	-0,145417	ID
		-0,738420	CA

As variáveis de entrada relevantes para cada uma das variáveis de resposta são apresentadas na Tabela 3.

Tabela 3: Variáveis de entrada e saída para os algoritmos.

Saída	Entradas				
Peso Médio	CONS	GPD	ID	-	-
Índice de Eficiência Produtiva	GPD	VIAB	CONS	ID	CA

3.2 Algoritmos

Utilizando a linguagem Python, implementou-se duas redes neurais seguindo o modelo *Multilayer Perceptron* com algoritmo de aprendizado por retropropagação de erros (MLP). As redes modeladas foram especificadas como: MLP 5-3-1 com 5 neurônios na camada de entrada, 3 neurônios na camada oculta e 1 na camada de saída e MLP 3-2-1 com 3 neurônios na camada de entrada, 2 neurônios na camada oculta e 1 na camada de saída (Figura 2).




Figura 2: Redes MLP 5-3-1 e MLP 3-2-1.

As equações de regressão linear obtidas, utilizando a função *linearregression()* da biblioteca *Scikit-learn* do Python, são apresentadas nas Equações 6 e 7.

$$PM = 0,0454GPD + 0,00284CONS + 0,0612ID - 2,796 \quad (6)$$

$$IEP = 10,361GPD - 48,295CA - 59,978CONS + 3,655VIAB + 6,09ID - 550,09 \quad (7)$$

Na Figura 3, é apresentado, como exemplo, a curva de aprendizagem para a variável IEP. Pode-se observar, por meio da figura, a boa convergência das curvas de treino e teste.

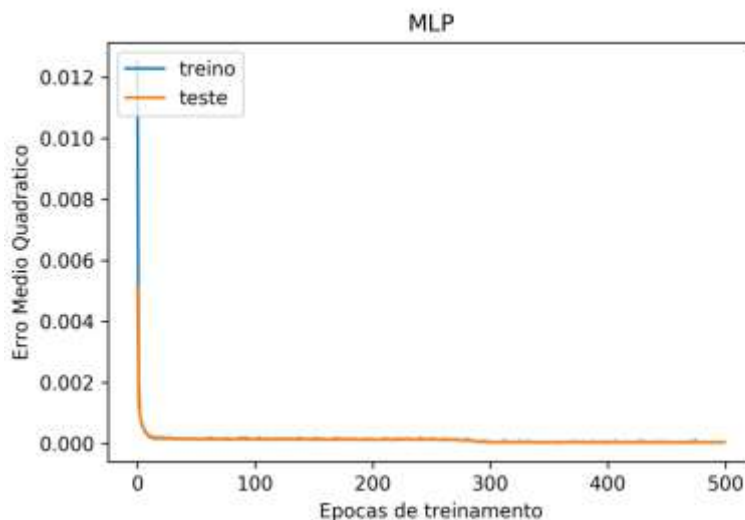


Figura 3: Curvas de aprendizagem de treino e teste - IEP.

A Tabela 4 apresenta os resultados obtidos, dos dois algoritmos (LR e MLP), para as variáveis de resposta Índice de Eficiência Produtiva (IEP) e Peso Médio (PM).

Tabela 4: Resultados da aplicação dos algoritmos MLP e LR.

Métricas	IEP		PM	
	LR	MLP	LR	MLP
Coeficiente de Correlação	0,9787	0,9989	0,9923	0,9991
Erro médio quadrático	0,006	0,00002	0,00025	0,00002
Raiz quadrada do erro médio quadrático	0,024	0,004	0,016	0,005

Verifica-se, por meio dos resultados apresentados na Tabela 4, que os dois algoritmos apresentam resultados muito próximos de coeficiente de correlação. As análises dos erros permitem verificar que os melhores resultados foram obtidos usando o algoritmo MLP para as variáveis em estudo (IEP e PM).

Na sequência, avaliou-se a dispersão dos valores preditos pelos dois algoritmos em relação aos valores observados para as duas variáveis de resposta (Figura 4).

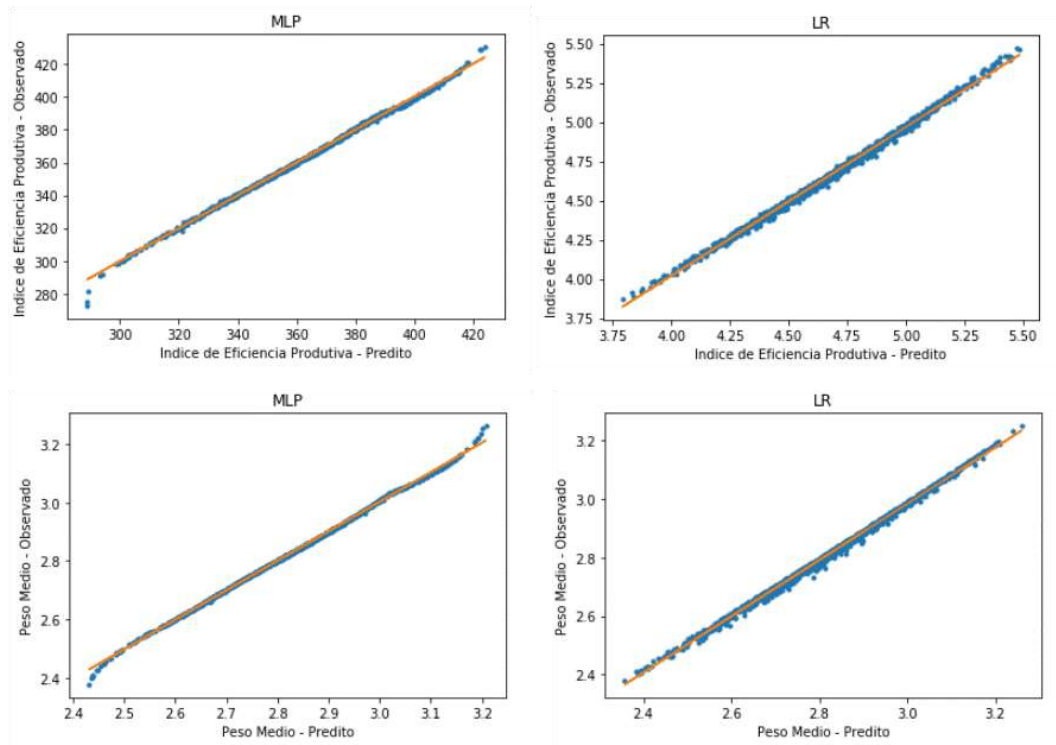


Figura 4: Dados preditos em função de dados observados.

Para validar os modelos, implementados neste trabalho, compararam-se resultados obtidos dos algoritmos com resultados obtidos de 150 lotes de frangos que não participaram da fase de teste e treinamento (Figura 5).

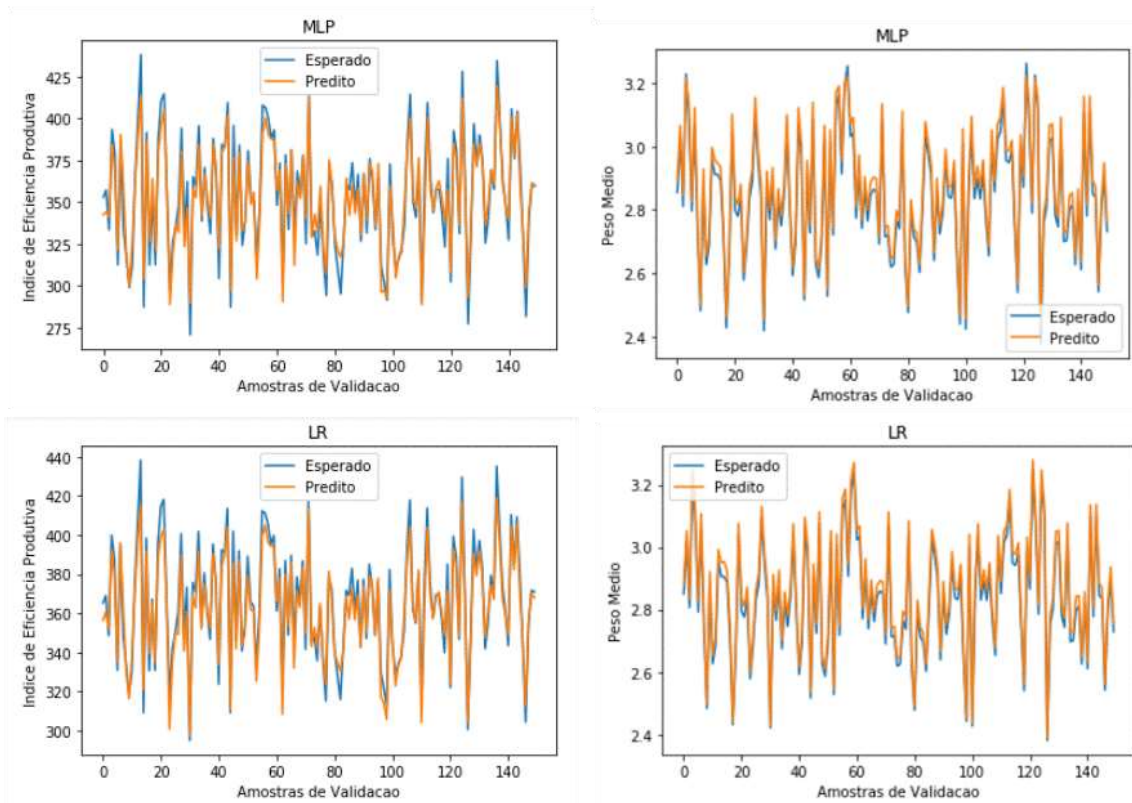


Figura 5: Dados preditos em função de dados observados – Conjunto de validação: 150 lotes.

Observa-se da Figura 4, que os dados experimentais apresentam uma boa correlação com os dados preditos para as duas variáveis produtivas, já que os pontos estão próximos a linha de ajuste. Pode-se também observar, por meio dos gráficos apresentados, na Figura 5, que existe uma boa aproximação entre os resultados reais e os previstos pelos dois algoritmos para o conjunto de dados de validação.

ANOVA: A análise de variância (ANOVA de fator único) com nível de significância (α) de 5% foi implementada com o objetivo de comparar as amostras do conjunto de dados de validação com as amostras preditas pela rede neural, para as duas variáveis em estudo (IEP e PM) (Tabela 5).

Tabela 5: Análise de variância.

	IEP	PM
F Value	0,032	2,36
P Value	0,856	0,125

Como os *p-values* são maiores do que o nível de significância especificado ($\alpha = 5\%$) conclui-se que não houve diferença significativa entre as amostras

3.3 Preço da carne de frango

Diante da importância do setor da carne de frango de varejo no Brasil, sobretudo em razão do consumo por grande parte das famílias brasileiras, torna-se importante estabelecer uma análise de mercado, no estado maior consumidor nacional de frango, baseada num modelo de previsão que permita observar as tendências de mercado. Na Tabela 6, apresenta-se a análise descritiva dos dados dos preços do quilo da carne frango congelada e resfriada.

Tabela 6: Análise descritiva dos preços do quilo da carne de frango- CEPEA.

	Congelado (R\$/kg)	Resfriado (R\$/kg)
Quantidade	132	132
Média	3,258	3,238
Mínimo	2,273	2,202
Máximo	4,547	4,614
Desvio Padrão	0,594	0,6
Coeficiente de Variação (%)	18,2	18,5

Pode-se observar, da Tabela 6, que os preços médios, para o período de 11 anos, ficaram em média de R\$ 3,258 para o kg de frango congelado e de R\$ 3,238 para o frango resfriado, valores muito próximos. Apresentando também preços mínimos e máximos de R\$ 2,273 e R\$ 4,547 para a carne de frango congelado e R\$ 2,202 e R\$ 4,614 para a carne de frango resfriada.

Quanto menor o Coeficiente de Variação maior será a representatividade da média. Para os dois conjuntos de dados o valor do coeficiente de variação é maior que 10%, sendo considerado médio, o que indica uma certa variabilidade dos dados (PIMENTEL, 2000).

Cabe também salientar, que o consumo de carne de frango não tende a sofrer muitas alterações durante o ano, cabendo a fatores exógenos a responsabilidade pelas alterações no

preço. Um desses possíveis fatores são as variações cambiais, que podem reduzir, por exemplo, a oferta do produto no mercado externo causando uma redução dos preços no mercado interno.

3.4 Redes recorrentes

Nesta seção, apresentam-se os resultados, das previsões de curto prazo para o peso do quilo de frango congelado e resfriado, obtidos por meio da rede neural LSTM. Inicialmente, como exemplo, apresenta-se, na Figura 6, os resultados das previsões para o preço do quilo do frango congelado entre os meses de dezembro/2012 e dezembro/2017, totalizando 60 meses.




Figura 6: Resultados das previsões entre Dez/2012 e Dez/2017 – 60 meses.

Por meio dos resultados apresentados, na Figura 6, pode-se notar que as redes recorrentes têm uma boa capacidade de se ajustar aos problemas de séries temporais. Na sequência, para validação do modelo apresentam-se, na Tabela 7, as previsões do preço do quilo de frango congelado e resfriado, para os três primeiros meses de 2019.

Tabela 7: Resultados das previsões para Jan/Fev/Mar de 2019 – Preço do Quilo.

	LSTM (R\$/kg)	CEPEA (R\$/kg)
Congelado		
Janeiro	4,278	4,365
Fevereiro	4,227	4,295
Março	4,353	4,432
Resfriado		
Janeiro	4,292	4,376
Fevereiro	4,507	4,329
Março	4,421	4,5

Por meio dos resultados apresentados, na tabela 7, conclui-se que os resultados das previsões estão muito próximos aos do CEPEA. Observou-se também, nestas previsões, que a rede LSTM obteve um bom desempenho com os dados utilizados (Tabela 8).

Tabela 8: Métricas.

Métrica	Congelado	Resfriado
---------	-----------	-----------

MSE	0,01	0,015
RMSE	0,102	0,122
MAE	0,099	0,113

Nas Figuras 7 e 8, apresentam-se as evoluções das séries temporais dos preços do quilo do frango congelado e resfriado para os anos de 2008 à 2020. Sendo que a previsão para os últimos 24 meses (2019 e 2020) são apresentadas na cor vermelha.

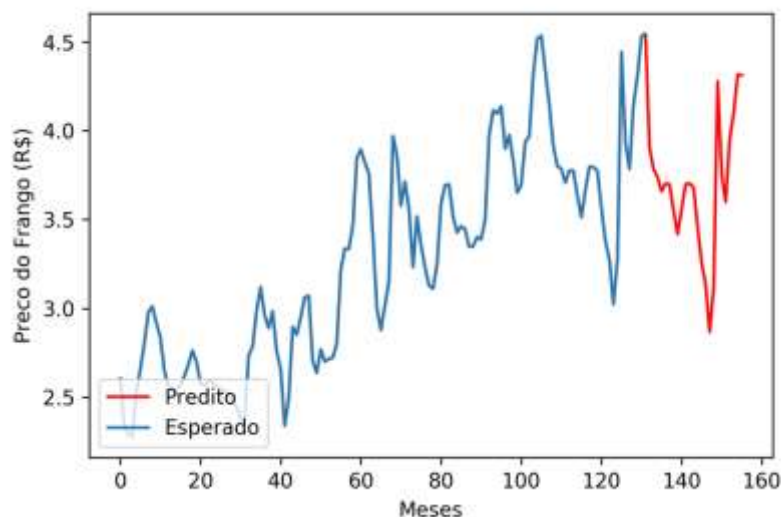


Figura 7: Resultados das previsões do preço do frango congelado.




Figura 8: Resultados das previsões do preço do frango resfriado.

4 CONCLUSÕES

Neste trabalho, com as variáveis produtivas obtidas, do banco de dados da empresa, construíram-se modelos de previsão baseados em dois algoritmos de análise de dados: Redes

Neurais Artificiais (MLP) e Regressão Linear (LR). Tais modelos passaram pelas fases de preparação de dados, definição das estruturas dos modelos, estimativas dos modelos, avaliação dos resultados dos modelos e validação dos modelos. Os resultados obtidos podem ser considerados relevantes, como demonstrados pela correlação entre os dados preditos e observados apresentados anteriormente.

Quando estes modelos, implementados para prever as variáveis de interesse, Peso Médio e Índice de Eficiência Produtiva, foram aplicados a um conjunto de validação com 150 lotes de frangos, que não participaram da fase de treinamento e teste, as previsões foram bem precisas e as diferenças entre valores reais e previstos foram pequenas. Portanto, a proximidade entre valores preditos e reais demonstram a boa capacidade de generalização dos modelos implementados neste trabalho.

Concluiu-se, por meio da técnica de correlação entre as variáveis obtidas do banco de dados, fornecido pela empresa, que a linhagem das aves não teve praticamente influência sobre as variáveis de resposta (IEP e PM).

Observou-se também que a rede recorrente LSTM obteve, para o conjunto de validação (janeiro, fevereiro e março de 2019), uma boa previsão dos valores do preço (R\$/kg) do quilo do frango tanto congelado como resfriado. Conclui-se então, que a rede LSTM pode ser usada, como ferramenta de previsão nas tomadas de decisão, do preço do quilo do frango congelado e resfriado, para um horizonte de curto prazo. No entanto, deve-se levar em conta que a validade da previsão está associada com a qualidade e com o número de instâncias dos dados.

Por fim, vale ainda destacar que os modelos de redes neurais, implementados, neste trabalho, podem ser utilizados para gerar resultados que servirão de suporte a tomada de decisões pelos responsáveis da empresa em estudo. Podendo estes realizar simulações e medir a contribuição de cada variável no fenômeno em estudo.

5 REFERÊNCIAS

- AMRAEL, S.; MEHDIZADEH, S. A.; SALARI, S. (2017) Broiler weight estimation based in machine vision an artificial neural network. *British Poultry Science*. 58(2), 200-205.
- ASSOCIAÇÃO BRASILEIRA DE PROTEÍNA ANIMAL (ABPA). (2018) Relatório Anual Completo. Disponível em: http://abpa-br.com.br/files/RelatórioAnual_UBABEF_2015_DIGITAL.pdf. Acesso em: 12 nov 2018
- AZARIAS, P.; MATOS S. N.; SCANDELARI, L. (2009) Aplicação de mineração de dados para geração do conhecimento: um experimento prático. In *Anais...V Congresso Nacional de Excelência em Gestão*. Niterói RJ.
- BASTIANI, M.; SANTOS, J. A. A.; SCHMIDT, C. A P.; SEPULVEDA, G. P. L. (2018) Application of data mining algorithms in the management of the broiler production. *Geintec*. 8(4), 4574-4587.
- BRAGA, A. (2019) Aplicando o Algoritmo de Memória de Longo Prazo para Previsualizar a Perda de Capacidade de Termorregulação em Colônias de Abelhas. . In *Anais...X Workshop de Computação Aplicada a Gestão do Meio Ambiente e Recursos Naturais*. Porto Alegre RS.

- CAMPOS, P. A. C. (2006) Aplicação do modelo ARIMA para previsão do preço do frango inteiriço no grande atacadado do estado de São Paulo. In... XIII Congresso Brasileiro de Custos. Belo Horizonte MG.
- CANKURT, S.; SUBASI, A. (2015) Comparation of linear regression and neural network models forecasting tourist arrivals to turkey. *Eurasian Journal of Science & Engineering*.
- CENTRO DE ESTUDOS AVANÇADOS EM ECONOMIA APLICADA (CEPEA). Preço do frango CEPEA/ESALQ - Estado SP. Disponível em: <https://www.cepea.esalq.usp.br/br/indicador/frango.aspx>. Acesso em: 19 set 2019.
- HAYKIN, S. (2005) Neural networks: a comprehensive foundation. New Delhi: Pearson Prentice Hall.
- HEIDARI, A. A. (2019) An efficient hybrid multilayer perceptron neural network with grasshopper optimization. *Soft Computing*. 23(17), 7941-7958.
- JOHASEN, S. V.; BENDTSEN, J. D.; MOGENSEN, J. (2019) Broiler slaughter weight forecasting using dynamic neural network models. In... IEEE 6th International Conference (ICIEA), Tokio JP.
- JÚNIOR, J. G. G; BENTO, E. F.; SOUZA, A. F. (2009) Diagnóstico da realidade dos criatórios de aves na comunidade base física - Ipangaçu/RN. *Revista Holos*. 4(1), 120-126.
- PIACENTI, C. A. (2007) O preço do frango de corte: Evolução e tendências no Brasil. *Cadernos de Economia*. 21(11), 79-94.
- PIMENTEL, F. G. (2000) Curso de estatística experimental. Piracicaba: Degaspari.
- SANTOS, R. B.; RUPP, M., BONZI, S. J.; FILETI, A. M. F. (2013) Comparison between multilayer feed forward neural networks and a radial basis function network to detect and locate leaks in pipes transporting gás. *Chemical Engineering Transactions*. 32(1), 1375-1380.
- SEBASTIAN, S. (2016) Performance evaluation by artificial neural network using WEKA. *International Research Journal of Engineering and Technology*, 3(3), 1459-1464.
- SING, G. P.; KUMAR, R.; SHARMA, A. (2017) QSAR Studies of breast carcinoma using artificial neural network, bayesian classifier and multiple linear regression. *International Research Journal of Engineering and Technology*, 4(5), 1443-1447.
- SOBRINHO, R. F. (2010) Competitividade na cadeia de valor da avicultura de corte. Dissertação de mestrado. Toledo, PR, UNIOESTE.
- UBA, União Brasileira de Avicultura. (2008) Protocolo de Boas Práticas de Produção de Frangos. São Paulo: UBA.
- ZAO, Z. (2017) LSTM network: a deep learning approach for short-term traffic forecast. *IET Intelligent Transport Systems*. 11(2), 68-75.