

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DIRETORIA DE PESQUISA E PÓS-GRADUAÇÃO
MESTRADO EM TECNOLOGIAS COMPUTACIONAIS PARA O AGRONEGÓCIO

TASSIO CARNEIRO PINHEIRO

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

MEDIANEIRA

2020

TASSIO CARNEIRO PINHEIRO

**GESTÃO DA PRODUÇÃO DE FRANGOS DE CORTE POR
MEIO DE REDES NEURAS ARTIFICIAIS**

**Management of the Production of Broiler Chikens through Artificial
Neural Network**

Dissertação apresentada como requisito para
obtenção do título de Mestre em Tecnologias
Computacionais para o Agronegócio da Universidade
Tecnológica Federal do Paraná (UTFPR).

Orientador: Prof. Dr. José Airton A. dos Santos

Coorientador: Prof. Me. Jorge Aikes Junior

MEDIANEIRA

2020



4.0 internacional

Esta obra está licenciada sob uma Licença Creative Commons
Atribuição, Não Comercial, Compartilha Igual 4.0 Internacional (CC BY-
NC-SA 4.0). Para ver uma cópia desta licença, visite o endereço
<http://creativecommons.org/licenses/by-nc-sa/4.0/> ou envie uma carta
para Creative Commons, PO Box 1866, Mountain View, CA 94042, USA.



TERMO DE APROVAÇÃO

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

Por

Tassio Carneiro Pinheiro

Essa dissertação foi apresentada às nove horas do dia vinte e sete de março de dois mil e vinte, como requisito parcial para a obtenção do título de Mestre em Tecnologias Computacionais para o Agronegócio, Linha de Pesquisa Tecnologias Computacionais Aplicadas À Produção Agrícola no Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio - PPGTCA, da Universidade Tecnológica Federal do Paraná. O candidato foi arguido pela Banca Examinadora composta pelos professores abaixo. Após deliberação, a Banca Examinadora considerou o trabalho

Banca Examinadora:

Prof. Dr. Jose Airton Azevedo dos Santos (Orientador – PPGTCA)

Prof. Dr. Paulo Cesar Tonin (Membro Interno – PPGTCA)

Dr. Leandro Antonio Pasa (Membro Externo - UTFPR)

Dr. Marcos Ricardo Muller (Membro Externo - IFPR) com participação à distância, sendo a assinatura no presente termo dispensada conforme Regulamento da Pós-Graduação Stricto Sensu da UTFPR).

A via original com as assinaturas encontra-se na secretaria do programa.

A Deus, aos meus pais, a
minha esposa e filha, e aos meus
amigos e companheiros de todas as
horas.

AGRADECIMENTOS

Ao Prof. Dr. Orientador, braço amigo de todas as etapas deste trabalho.

A minha família, em muito especial a minha companheira de vida, pela confiança, motivação e paciência.

Aos amigos e colegas, pela força e pela vibração em relação a esta jornada.

Aos professores e colegas de Curso, pois juntos trilhamos uma etapa importante de nossas vidas.

A todos que, com boa intenção, colaboraram para a realização e finalização deste trabalho.

"Se existe uma forma
de fazer melhor, descubra-a."

Thomas Edison

RESUMO

Carneiro Pinheiro, Tassio. **GESTÃO DA PRODUÇÃO DE FRANGOS DE CORTE POR MEIO DE REDES NEURAIIS ARTIFICIAIS**. 2020. Projeto (Pós-graduação em Tecnologias Computacionais para o Agronegócio) - Universidade Tecnológica Federal do Paraná.

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 da aplicabilidade de redes neurais recorrentes utilizou-se, neste trabalho, duas bases de dados, com preços mensais, compreendidas entre janeiro de 2008 e dezembro de 2019, representando 132 observações. 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.

ABSTRACT

Carneiro Pinheiro, Tassio. **MANAGEMENT OF THE PRODUCTION OF BROILER CHICKENS THROUGH ARTIFICIAL NEURAL NETWORKS**. 2020. Dissertation (MSc ind Computational Technologies for Agribusiness) – Post – Graduate Program in Computational Technologies for Agribusiness, Federal Technologies University of Paraná.

Currently, the globalized and highly competitive environment imposes on broiler production companies two major challenges: optimizing resources and reducing costs. In this context, this work aims to use artificial neural networks and multiple linear regression for the analysis and forecast of productive variables of broilers in a Paraná agribusiness. It is also analyzed the applicability of recurrent neural networks in the prediction of the price of the kilo of frozen and chilled broiler. The database provided by the company has a 2-year history of movement, containing the main production variables, for 4650 batches of broilers of the Coob, Coob Fast and Coob Slow lines. In the analysis of the applicability of recurrent neural networks, in this work, two databases were used, with monthly prices, between January 2008 and December 2019, representing 132 observations. The results obtained show that the forecasting models provide reliable estimates for the response variables: Average Weight and Productive Efficiency Index and demonstrate the effectiveness of the forecasts, from the recurring LSTM network, for the price of the kilo of frozen and chilled broiler, for a short-term horizon.

Key-words: Artificial Neural Network; Broiler Chickens; Agroindustry.

LISTA DE FIGURAS

| | |
|---|-----|
| Figura 1 - Estrutura da cadeia produtiva de frango de corte | 19 |
| Figura 2 - Frangos de corte - Aviário | 20 |
| Figura 3 - Frangos de corte – Linha de abate | 20 |
| Figura 4 - Neurônio biológico | 22 |
| Figura 5 - Estrutura de um Neurônio | 23 |
| Figura 6 - Função sigmóide..... | 24 |
| Figura 7 - Arquitetura de uma rede MLP | 25 |
| Figura 8 - Processo de <i>backpropagation</i> | 26 |
| Figura 9 - Métodos preditivos | 26 |
| Figura 10 - Série temporal..... | 27 |
| Figura 11 - Rede recorrente desdobrada | 28 |
| Figura 12 - Célula LSTM | 30 |
| Figura 13 - Jupyter notebook..... | 32 |
| Figura 14 – Estado do Paraná..... | 34 |
| Figura 15 - Preço da carne de frango congelado e resfriado | 35 |
| Figura 16 - Peso Médio (kg)..... | 36 |
| Figura 17 - <i>Boxplots</i> – Preço da carne de frango | 37 |
| Figura 18 - Código em KERAS da rede neural LSTM | 40 |
| Figura 19 – Validação cruzada..... | 453 |
| Figura 20 - <i>Boxplots</i> e gráfico de dispersão – PM..... | 45 |
| Figura 21 - <i>Boxplots</i> e gráfico de dispersão – IEP | 46 |
| Figura 22 - Redes MLP 5-3-1 e MLP 3-2-1 | 48 |
| Figura 23 - Curvas de aprendizagem de treino e teste – IEP e PM | 49 |
| Figura 24 - Dados preditos em função de dados observados | 50 |
| Figura 25 - Dados preditos em função de dados observados – Conjunto de validação: 150 lotes..... | 51 |
| Figura 26 – <i>Boxplots</i> – IEP e PM | 52 |
| Figura 27 - Resultados das previsões – 60 meses..... | 54 |
| Figura 28 - Preço do quilo do frango – congelado e resfriado..... | 55 |
| Figura 29 - Resultados das previsões do preço do frango congelado..... | 56 |
| Figura 30 - Resultados das previsões do preço do frango resfriado | 57 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 1 - Dez primeiros registros do arquivo de dados | 37 |
| Tabela 2 - Métricas para avaliação | 41 |
| Tabela 3 - Análise descritiva de dados – Agroindústria..... | 44 |
| Tabela 4 - Classificação dos atributos..... | 47 |
| Tabela 5 - Variáveis de entrada e saída para os algoritmos | 47 |
| Tabela 6 - Resultados da aplicação dos algoritmos MLP e LR | 50 |
| Tabela 7 - Análise de variância | 52 |
| Tabela 8 - Resultados da aplicação do algoritmo MLP – <i>Cross-validation e Holdhout</i> | 53 |
| Tabela 9 - Análise descritiva do preço da carne de frango | 54 |
| Tabela 10 - Resultados das previsões para Jan/Fev/Mar de 2019 – Preço do Quilo | 55 |

LISTA DE QUADROS

| | |
|--|----|
| Quadro 1 - Posição mundial do Brasil em produção e exportação..... | 18 |
|--|----|

SUMÁRIO

| | |
|--|----|
| 1 INTRODUÇÃO | 14 |
| 2 OBJETIVOS | 16 |
| 2.1 OBJETIVO GERAL | 16 |
| 2.2 OBJETIVOS ESPECÍFICOS | 16 |
| 3 REVISÃO DE LITERATURA | 17 |
| 3.1 Avicultura brasileira | 17 |
| 3.2 Cadeia produtiva de frangos de corte | 19 |
| 3.3 Linhagem das aves | 21 |
| 3.4 Redes neurais | 21 |
| 3.5 Métodos de previsão | 26 |
| 3.6 Séries temporais | 27 |
| 3.7 Redes recorrentes | 28 |
| 3.8 Regressão linear | 30 |
| 3.9 Python | 31 |
| 3.10 Jupyter..... | 31 |
| 4 MATERIAIS E MÉTODOS..... | 33 |
| 4.1 Tipo de pesquisa | 33 |
| 4.2 A empresa | 33 |
| 4.3 Base de dados | 34 |
| 4.4 Tratamento dos dados..... | 35 |
| 4.5 Estatísticas sobre os dados..... | 37 |
| 4.6 Índice de eficiência produtiva e peso médio..... | 38 |
| 4.7 Recursos | 39 |
| 4.8 Normalização | 40 |

| | |
|--------------------------------------|-----|
| 4.9 Parâmetros – redes neurais | 40 |
| 4.10 Métricas..... | 41 |
| 4.11 Métodos de fragmentação..... | 42 |
| 5 RESULTADOS | 44 |
| 5.1 Seleção de atributos..... | 46 |
| 5.2 Algoritmos | 47 |
| 5.3 Redes recorrentes..... | 533 |
| CONCLUSÃO..... | 58 |
| REFERÊNCIAS..... | 60 |

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 efeitos positivos 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). Neste sentido, as Redes Neurais Artificiais (RNA) podem ser utilizadas como ferramentas de apoio no processo de tomada de decisão. Tais ferramentas são 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.* (2017) 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 o modelo ARIMA.

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 OBJETIVOS

Nesse tópico será descrito os objetivos gerais e específicos de modo a delimitar o escopo e vislumbrar os resultados esperados.

2.1 OBJETIVO GERAL

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.

2.2 OBJETIVOS ESPECÍFICOS

- a) Analisar a literatura existente em relação ao tema proposto.
- b) Obter um banco de dados com índices zootécnicos para as linhagens *Coob*, *Coob Fast* e *Coob Slow*.
- c) Realizar o tratamento dos dados.
- d) Implementar modelos de regressão linear múltipla e redes neurais artificiais MLP, na linguagem Python, para previsão dos pesos e dos Índices de Eficiência Produtiva de aves de uma agroindústria, localizada no estado do Paraná.
- e) Implementar um modelo de rede neural artificial LSTM e verificar sua aplicabilidade na previsão dos preços (R\$/kg) de frangos congelados e resfriados.
- f) Testar e validar os modelos.

3 REVISÃO DE LITERATURA

Neste capítulo, a revisão de literatura abordará conceitos teóricos pertinentes a realização deste trabalho. Inicialmente, será realizada uma abordagem sucinta sobre a avicultura brasileira para posteriormente apresentar um enfoque especial sobre redes neurais artificiais (RNA).

3.1 AVICULTURA BRASILEIRA

A chegada da avicultura no Brasil está relacionada ao descobrimento do nosso país. Por volta de 1502, a comitiva de Pero Vaz de Caminha, atracou na Bahia, trazendo a bordo das caravelas, as primeiras matrizes. Estas matrizes, originadas dos cruzamentos de várias raças, eram criadas nos quintais das casas (ABPA, 2018).

No final dos anos 50, começou no Brasil a produção independente de frangos de corte, onde os produtores compravam os insumos no mercado, engordavam os frangos e os comercializavam para os frigoríficos (CUNHA, 2014).

O sistema de produção integrada começou em Santa Catarina, no início dos anos 60, seguindo um padrão de gerenciamento utilizado nos Estados Unidos. Na seqüência, este padrão foi adotado pelos demais estados da união, trazendo várias mudanças para o setor (CUNHA, 2014).

Rizzi (1993), ao analisar o desenvolvimento histórico da atividade, considera os anos 70 como o período mais importante para a evolução da produção de carne de frango. Nesta década, a atividade deixou de ser concentrada na região sudeste e migrou para o sul do país. Neste período, a proximidade entre as empresas as fortaleceu e estimulou sua concentração geográfica, levando ao melhoramento do processo de produção e das técnicas de manejo.

Nos anos 80 ocorreu um movimento de expansão da fronteira agrícola. Acontecendo uma migração das empresas avícolas para outras regiões, buscando uma proximidade com os fornecedores de matéria-prima utilizada para ração. Nesta

década aconteceu a retração do mercado interno, decorrente da recessão generalizada na economia brasileira. A primeira metade dos anos 80 foi o único período de baixo crescimento da produção, compensado, entretanto, pelo crescimento das exportações (CUNHA, 2014).

Nas últimas décadas, a cadeia produtiva do frango de corte está em evidência, no agronegócio brasileiro, devido as diversidades de recursos tecnológicos utilizados e a eficácia no seu gerenciamento. A avicultura brasileira, bem sucedida no mercado interno, possui também uma posição impar no cenário avícola internacional. A competitividade do setor resulta, em grande parte, de sua disponibilidade de grãos e de suas condições climáticas. No Quadro 1 apresenta-se, em níveis de produção e exportação de carne de frango, a posição do Brasil entre os os anos de 1996 e 2017.

Quadro 1 - Posição mundial do Brasil em produção e exportação

| Ano | Posição do Brasil | |
|------|-------------------|------------|
| | Produção | Exportação |
| 1996 | 4 | 2 |
| 1997 | 4 | 2 |
| 1998 | 4 | 2 |
| 1999 | 3 | 2 |
| 2000 | 3 | 2 |
| 2001 | 3 | 2 |
| 2002 | 2 | 3 |
| 2003 | 3 | 2 |
| 2004 | 3 | 2 |
| 2005 | 3 | 2 |
| 2006 | 3 | 1 |
| 2007 | 3 | 1 |
| 2008 | 3 | 1 |
| 2009 | 3 | 1 |
| 2010 | 3 | 1 |
| 2011 | 3 | 1 |
| 2012 | 3 | 1 |
| 2013 | 3 | 1 |
| 2014 | 3 | 1 |
| 2015 | 2 | 1 |
| 2016 | 2 | 1 |
| 2017 | 2 | 1 |

Fonte: (DVOJATZKI, 2017).

3.2 CADEIA PRODUTIVA DE FRANGOS DE CORTE

O Brasil possui uma tecnologia moderna, na cadeia produtiva de frangos de corte, a ponto de obter patamares de produtividade semelhantes a países mais avançados tecnologicamente. Os altos níveis de desenvolvimento industrial e de criação de aves combinados com a genética, proporcionam a evolução das taxas de conversão alimentar, precocidade e sobrevivência (RICHETTI; SANTOS, 2010).

Voila e Triches (2012) definem a cadeia produtiva conforme apresentado na Figura 1.

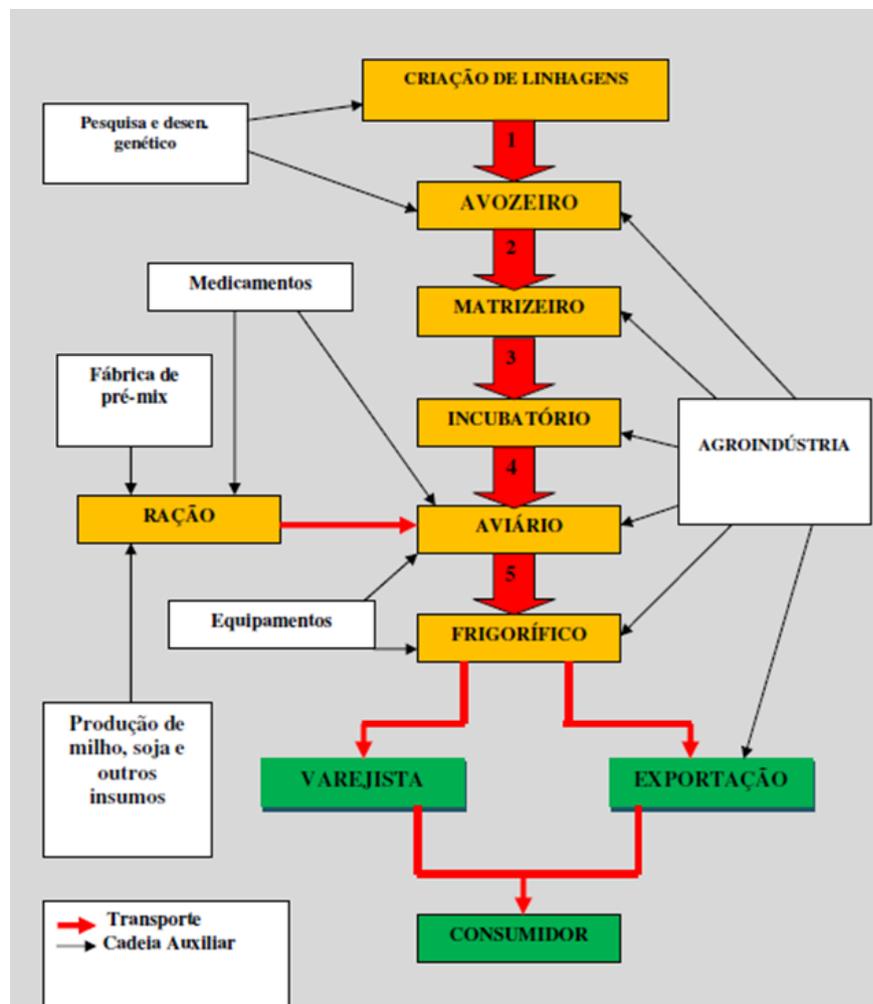


Figura 1 - Estrutura da cadeia produtiva de frango de corte

Fonte: (VOILA; TRICHES, 2012)

O primeiro elo da produção de frangos de corte é o cultivo do milho e da soja, utilizados nas indústrias de rações (CUNHA, 2014).

Na próxima etapa, as matrizes são originadas do cruzamento entre as linhagens das aves. Estas matrizes geram ovos que são encaminhados para um incubatório. Depois de chocados são enviados ao nascedouro.

Na seqüência, os animais são levados, aos aviários (Figura 2), para serem criados e engordados até a etapa do abate.



Figura 2 - Frangos de corte - Aviário

Fonte: (VOILA; TRICHES, 2012)

O próximo elo da cadeia é o frigorífico. Neste estágio os frangos são abatidos (Figura 3) e passam por inúmeras etapas até ficarem prontos para o consumo, podendo ser comercializados inteiros ou em partes.



Figura 3 - Frangos de corte – Linha de abate

Fonte: (ABPA, 2018)

Depois disso, os produtos são repassados aos varejistas e ao mercado consumidor.

Observa-se que o setor da avicultura reúne mais de 3,5 milhões de trabalhadores. Cerca de 350 mil trabalham nas plantas frigoríficas. No campo, tem-se mais de 130 mil famílias proprietárias de pequenos aviários, que produzem em um sistema totalmente integrado com as agroindústrias (ABPA, 2018).

3.3 LINHAGEM DAS AVES

Os avanços em pesquisa de melhoramento genético foram os grandes responsáveis por transformar o frango de corte em um animal extremamente competitivo, reduzindo seu ciclo de crescimento e diminuindo seu consumo de alimento (CUNHA, 2014).

A EMBRAPA (2017) avalia que um número superior a 300 raças puras de aves e suas variedades já foram desenvolvidas até o momento, sendo que um valor bem expressivo possui representação comercial. Algumas das raças mais antigas ainda hoje são mantidas em estações relacionadas a experimentos genéticos. Por isso, deve-se ter ciência de que o banco genético das linhagens serve como combustível para os cruzamentos que dão origem a diversidade das raças híbridas modernas. Em frangos de corte as linhagens mais utilizadas são: *Coob* (CB), *Coob Fast* (CF), *Coob Slow* (CS) e *Roos* (RO). Hoje, o desempenho esperado dos híbridos de frangos de corte, aos 42 dias, é de um peso médio de 2,626 kg.

Atualmente, ocorre uma contínua busca pela melhoria do material genético, utilizado nas linhagens de frangos de corte, em virtude da evolução e da competitividade existente na indústria avícola. Com isso, são realizadas pesquisas para identificar linhagens que apresentem características superiores em relação ao desempenho produtivo e rendimento da carcaça (EMBRAPA, 2017).

3.4 REDES NEURAIAS

É possível aplicar redes neurais artificiais nos mais diversos campos de pesquisa. Entre aplicações típicas de RNA pode-se citar: diagnósticos médicos, análise de dados econômicos, processos de produção, dentre outras. Atualmente, as RNAs estão sendo utilizadas com um enfoque mais comercial, para uma grande variedade de tarefas em diversas áreas do comércio, da indústria e da ciência (HAYKINS, 2005).

A inspiração para a criação de redes neurais artificiais surgiu da tentativa de compreender o cérebro humano. As redes neurais artificiais são muito parecidas com as redes biológicas, tendo estrutura, função, técnicas de processamento de dados e métodos de cálculo muito similares. As redes neurais artificiais podem aprender com os dados e resolver problemas complexos (CAMILO; SILVA, 2019).

Neurônio Biológico:

O cérebro humano é composto por um grande número neurônios, aproximadamente 10 bilhões. Cada neurônio biológico (Figura 4) é uma célula especializada que pode criar, receber e propagar sinais eletroquímicos (GOLDSCHMIDT; PASSOS, 2005; BASTIANI, 2017).

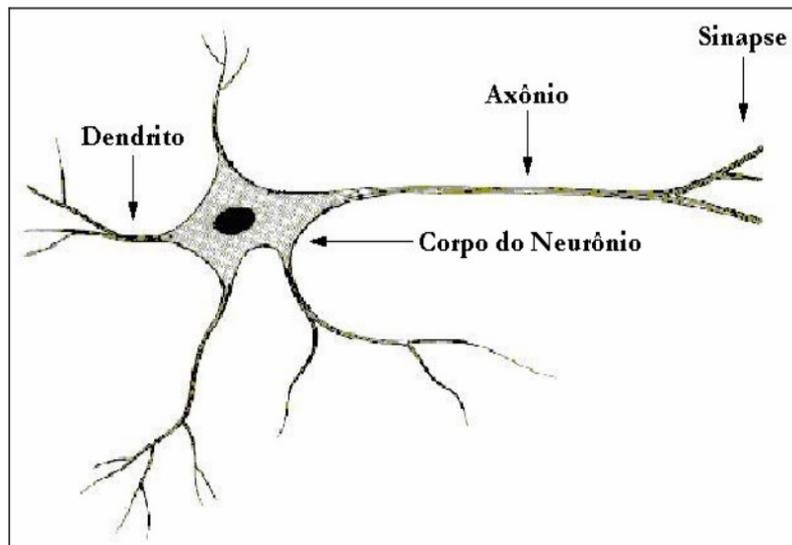


Figura 4 - Neurônio biológico

Fonte: (GOLDSCHMIDT; PASSOS, 2005)

O neurônio biológico é composto por: corpo celular; dendritos; axônio e

suas terminações, as sinapses. As informações de entrada obtidas de outros neurônios são recebidas pelos dendritos, que conduzem essas informações para o corpo celular (Corpo do Neurônio). No corpo celular esta informação é processada e outro impulso flui para o axônio. Caso este esteja conectado com outro neurônio, a informação será repassada.

As sinapses constituem o patamar fundamental quando se trata de organização anatômica do cérebro. Em patamares superiores temos os microcircuitos neurais, que nada mais são do que sinapses agrupadas para uma determinada operação funcional. O conjunto desses circuitos formam subunidades dendritais dentro das árvores dos neurônios, que são numerosas em um neurônio. Em seqüência, têm-se os circuitos locais, que são conjuntos de neurônios. Posteriormente, tem-se os circuitos inter-regionais, formados por caminhos, colunas, mapas topográficos, abrangendo diversas áreas do cérebro (BASTIANI, 2017).

É importante ressaltar que os neurônios que formam as redes neurais artificiais são primitivos em comparação com aqueles encontrados no cérebro.

Neurônio Artificial:

O neurônio artificial (Figura 5) também é composto por: dendritos (entradas), corpo celular (unidade de processamento) e terminais de axônio (saída).

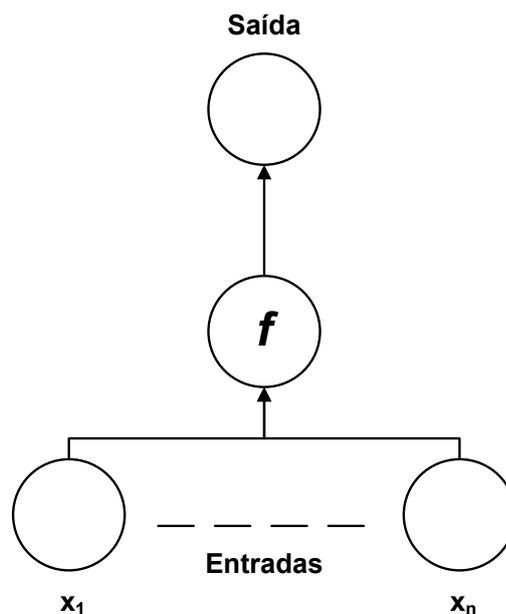


Figura 5 - Estrutura de um neurônio artificial

Fonte: (HAN; KAMBER, 2006)

Os neurônios artificiais recebem sinais de muitas fontes. Estas fontes são referidas como variáveis de entrada x_i , ou simplesmente entradas. As entradas são recebidas por conexões que possuem uma determinada “força”, chamada de peso w_i . Ao receber os sinais uma soma ponderada (soma dos pesos) das entradas é formada, para compor a função de ativação f . A função de ativação do neurônio (Equação 1) é uma função matemática que converte a soma dos pesos dos sinais na saída do neurônio (SILVA, 2015; BASTIANI, 2017).

$$f = (w_1x_1 + w_2x_2 \dots \dots + w_nx_n) \quad (1)$$

Pode-se usar como função de ativação f várias funções matemáticas. Dentre elas pode-se citar a: Identidade; Logística; Exponencial; Tangente hiperbólica; Sigmóide, etc. Por exemplo, a função sigmóide, apresentada na Figura 6, é definida como uma função estritamente crescente que exibe um balanceamento adequado entre o comportamento linear e não linear (BASTIANI, 2017).

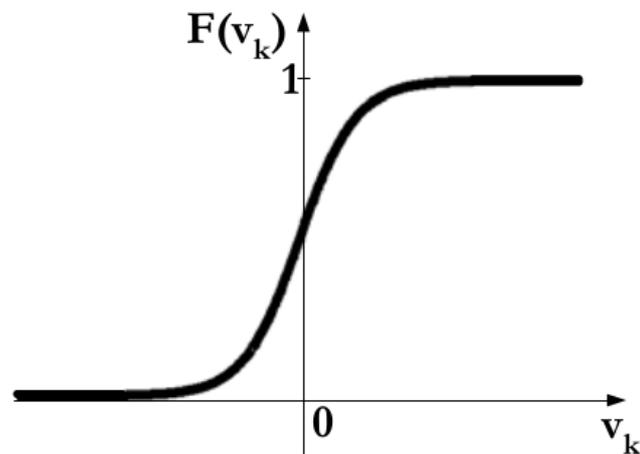


Figura 6 - Função sigmóide

Fonte: (HAN; KAMBER, 2006)

Redes Multilayer Perceptron (MLP):

O treinamento de uma RNA é o processo de ajuste de seus pesos, através de um algoritmo de aprendizagem, que extrai características dos dados fornecidos e tem por objetivo gerar uma rede que desempenhe a tarefa de interesse

(BINOTI, 2010). As redes treinadas, neste trabalho, são do tipo *perceptron* de múltiplas camadas (Figura 7), conhecidas como MLP (*Multilayer Perceptron*).

As redes MLP são utilizadas para resolver diversos tipos de problemas através de seu treinamento *backpropagation* (SILVA, 2015; BASTIANI, 2017). São constituídas por uma camada de entrada, uma ou mais camadas escondidas (ou intermediárias) e uma camada de saída. São consideradas redes progressivas (*feedforward*). Nestas redes as saídas dos neurônios de uma determinada camada se conectam apenas às entradas dos neurônios da camada seguinte. As redes MLP apresentam uma função de ativação para cada neurônio na rede.

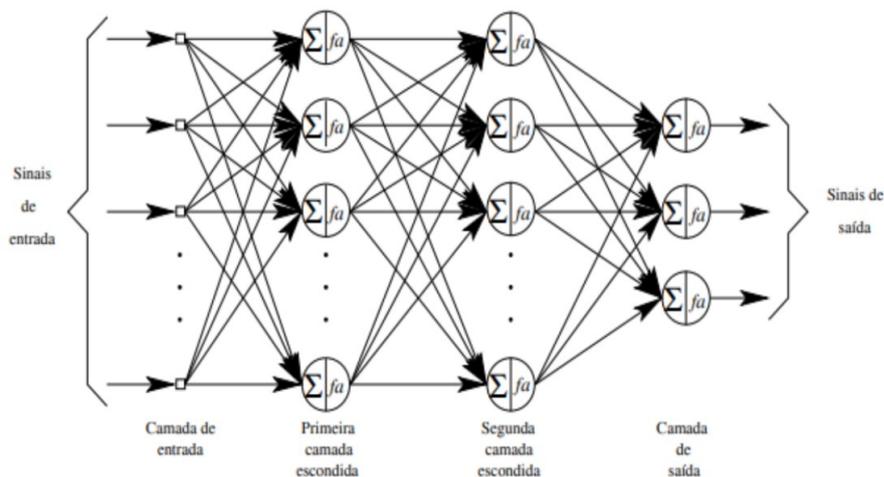


Figura 7 - Arquitetura de uma rede MLP

Fonte: (HAN; KAMBER, 2006)

Algoritmo *Backpropagation*:

O algoritmo *backpropagation* é o mais usado algoritmo de aprendizagem supervisionada, que busca minimizar o erro obtido e reajustar os pesos associados (BINOTI, 2010). O objetivo é ajustar os pesos da rede, modificando-os até que a aplicação de um conjunto de entradas produza a saída da rede que corresponda às saídas desejadas ou alvos.

Pode-se sintetizar a dinâmica do algoritmo de retropropagação em dois procedimentos básicos: a propagação do efeito de um vetor de entrada através da rede e a propagação do sinal do erro gerado na saída da rede em sentido contrário ao das conexões sinápticas, comumente chamado de retropropagação (Figura 8).

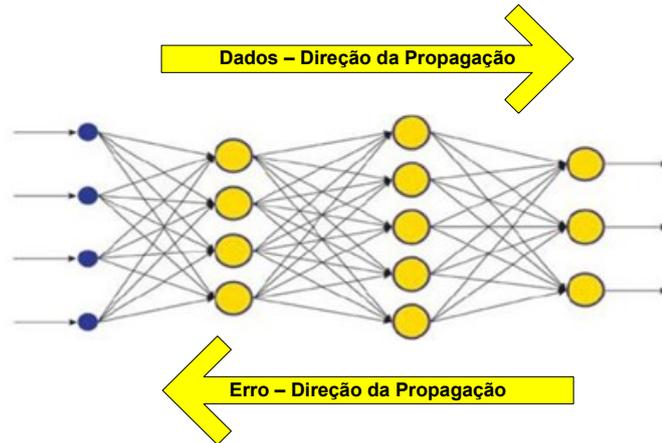


Figura 8 - Processo *backpropagation*

Fonte: (HAN; KAMBER, 2006)

Quando os padrões são entregues às entradas e seu efeito se propaga através da rede, os pesos sinápticos são fixos. Seu ajuste ocorre quando o sinal do erro é retropropagado através da rede.

3.5 MÉTODOS DE PREVISÃO

Quanto ao tipo de abordagem, as previsões podem ser classificadas em quantitativas e qualitativas (TUBINO, 2009) (Figura 9).

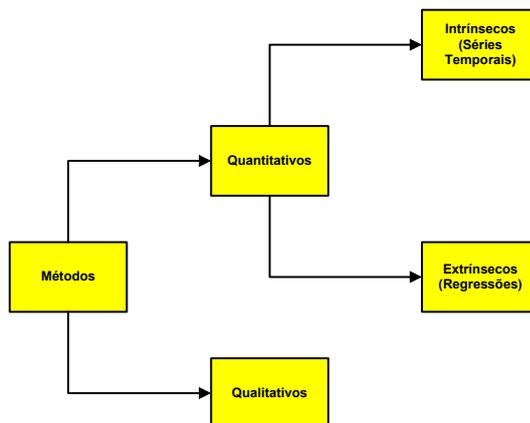


Figura 9 - Métodos preditivos

Fonte: Adaptado de Lustosa (2008)

O modelo qualitativo, baseado em dados de difícil representação

numérica, possui caráter subjetivo e tem o julgamento baseado em emoção, experiência profissional ou intuição (TUBINO, 2009).

No modelo quantitativo as técnicas fundamentam-se na análise de dados numéricos. Empregam modelos matemáticos para a previsão de demanda futura.

Neste trabalho utiliza-se um método quantitativo clássico, para previsão de séries temporais, as redes neurais recorrentes.

3.6 SÉRIES TEMPORAIS

Uma série temporal (Figura 10) é qualquer conjunto de observações ordenada no tempo. Por exemplo, podem-se citar: índices diários da bolsa de valores, valores de temperatura de uma cidade, precipitação anual, entre outros (MORETIN; TOLOI, 2004).

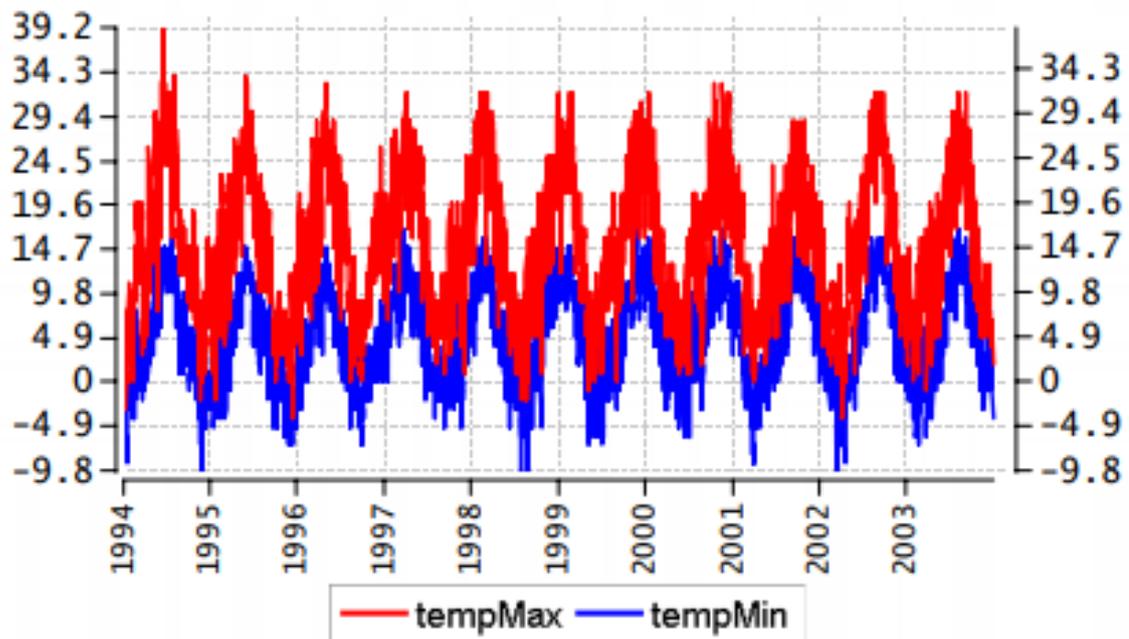


Figura 10 - Série temporal

Fonte: (MOREIRA, 2011)

A análise de séries temporais exige o conhecimento dos valores passados da variável estudada, distribuídos em intervalos de tempos iguais (MOREIRA, 2011).

O tempo é a única variável que influencia no processo de previsão baseado em séries temporais. Nesse caso, considera-se que o padrão observado no passado irá repetir-se no futuro, e fundamentado nessa premissa, gera-se novas previsões. A maior aplicação da análise de séries temporais é a geração de modelos de previsão. O uso desses modelos de previsão são fundamentais para diminuir os riscos nas tomadas de decisão (LUSTOSA, 2008).

Um fator importante, quando trata-se de séries temporais é o horizonte da previsão, sendo que quanto maior for o horizonte menos precisa será a projeção, ou seja, os modelos quantitativos como os modelos de redes neurais, tendem a ser mais adequados para previsões de curto prazo (CORRÊA; CORRÊA, 2012).

3.7 REDES RECORRENTES

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 estas estruturas tem-se as Redes Neurais Recorrentes (RNNs). As RNNs são redes em que as saídas dos neurônios são realimentadas como sinais de entrada para outros neurônios. Isto é, apresentam *loops* que permitem que a informação persista ao longo da rede (HAYKIN, 2005). Uma rede recorrente pode ser vista como uma cópia dela mesma, cada uma passando mensagem para seu sucessor. A Figura 11 ilustra uma rede desdobrada.

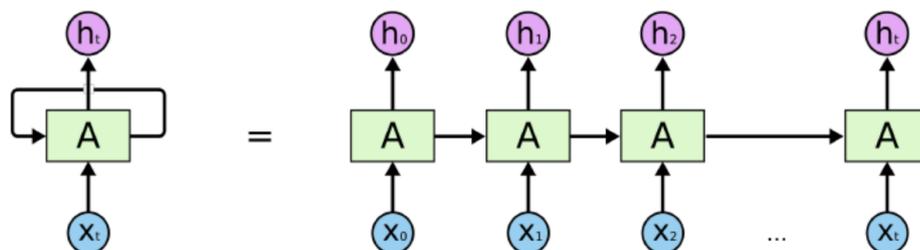


Figura 11 - Rede recorrente desdobrada

Fonte: (OLAH, 2015)

Nos últimos anos, as RNNs têm sido aplicadas em diversos problemas: modelagem de idiomas, tradução, séries temporais, entre outros. Em séries temporais tem-se como objetivo prever o próximo valor de acordo com valores anteriores. Portanto, a entrada para a RNN, em cada intervalo de tempo, é o valor atual, bem como o vetor de estado com os dados do período anterior, que é a memória. Em todos estes problemas a questão da seqüência e da memória são relevantes. Sendo que as redes *Long Short Term Memory* (LSTM) foram as que mais tiveram êxito dentre as redes recorrentes, porque lidam melhor com as dependências de longo prazos (BRAGA, 2019).

LSTMs:

As redes LSTMs são um tipo de rede neural recorrente, as quais são capazes de aprender dependências de longo prazo, o que não é possível com redes neurais recorrentes tradicionais (ZAO, 2017).

A topologia de um neurônio de uma LSTM é baseada em uma célula de memória. Uma célula de memória possui um componente de memória para armazenar seqüências recentes, o que o torna mais inteligente que um neurônio clássico. Cada célula contém portões, os quais controlam a quantidade de informação que é memorizada e a quantidade de informação que deve ser repassada para as próximas unidades.

Uma célula trabalha com uma seqüência de entrada (x_t) (Figura 12) e cada portão (*gate*) dentro de uma célula usa as unidades de ativação (σ , \tanh) para controlar se elas são acionadas ou não, fazendo com que a mudança de estado e a adição de informações fluam através da célula. O parâmetro (C_t) representa o estado da célula no instante (t), este estado representa as informações que chegaram até esse passo em instante de tempos passados, (f_t) o *gate* de esquecimento, que determina quais informações devem ser jogadas fora pela célula, (i_t) o *gate* de entrada, que determina os valores de entrada para atualizar o estado da célula e (O_t) o *gate* de saída que determina o que produzir com base na entrada e na memória da célula. Todos esses valores acabam sendo concatenados, multiplicados ou somados, conforme mostra o circuito apresentado na Figura 12 (GRAVES, 2014).

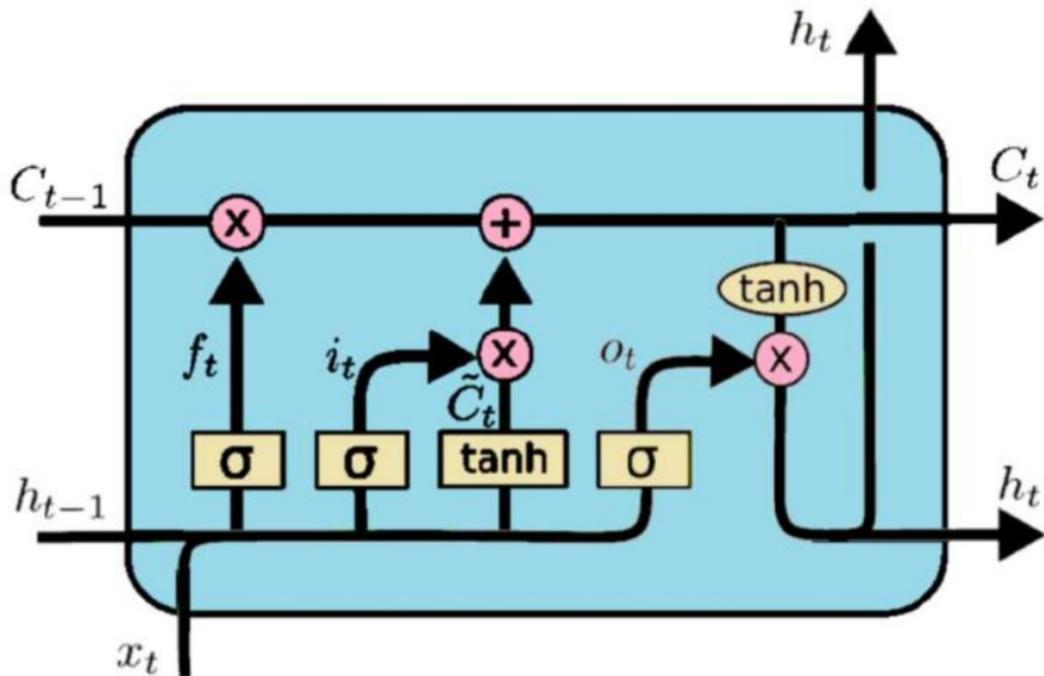


Figura 12 - Célula LSTM

Fonte: (GRAVES, 2014)

Por meio deste modelo de célula, as redes LSTM conseguem aprender dependências de longo prazo a partir de dados de uma estrutura temporal. A única diferença estrutural da LSTM para uma RNN tradicional é que seus elementos deixam de ser neurônios com funções de ativação e tornam-se blocos de memória (GRAVES, 2014).

3.8 REGRESSÃO LINEAR

Quando o resultado, ou classe, é numérica e todos os atributos são numéricos, a regressão linear é uma técnica a ser considerada. A idéia é expressar a classe como uma combinação linear de atributos, com pesos pré-determinados (BASTIANI, 2017):

$$y = w_0 + w_1 a_1 + w_2 a_2 + \dots + w_k a_k \quad (2)$$

Onde y 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. Em mineração de dados o algoritmo de regressão linear é muito utilizado para fazer previsão, e pode ser encontrado em vários softwares estatísticos (HAYKIN, 2005).

3.9 PYTHON

A linguagem de programação Python é muito interessante como primeira linguagem de programação devido à sua simplicidade e clareza. Embora simples pode ser usada para administrar sistemas e desenvolver grandes projetos (MENEZES, 2014).

A linguagem Python é uma linguagem de alto nível, de *script*, orientada a objetos e de tipagem dinâmica e forte. É uma linguagem *open source*, gratuita e tem uma ativa comunidade de programadores. É um ambiente poderoso para programação numérica e geração de gráficos. Python é uma linguagem completa, contando com bibliotecas para acessar bancos de dados, processar arquivos XML, construir interfaces gráficas, entre outros (MENEZES, 2014).

Após alguns anos de ajustes, a linguagem começou a tornar-se preferida entre alguns grupos de desenvolvedores, sendo usada em muitas das aplicações atuais. A rapidez com a qual os resultados são atingidos atrai os usuários, tendo como seus principais adeptos os usuários da comunidade de código aberto (SONGINI, 2005). Atualmente, tem ganhado apoio de empresas como Google e NASA, assim como por um conjunto crescente de empresas (EMAN *et al.*, 2018).

3.10 JUPYTER

O Jupyter, criado em 2014, é um projeto sem fins lucrativos de código aberto. É fruto da extensão do projeto IPython. Este projeto tem como objetivo criar um suporte em diversas linguagens de programação para o desenvolvimento da computação científica (JUPYTER STEERING COUNCIL, 2018). O projeto IPython, focado principalmente na linguagem de programação Python, consiste de um

interpretador iterativo para Python. Este projeto apresenta uma interface denominada *Notebook* que é executada como uma interface *web* no navegador (Figura 13). Permite a integração entre a execução do código, textos, expressões matemáticas, gráficos, etc.

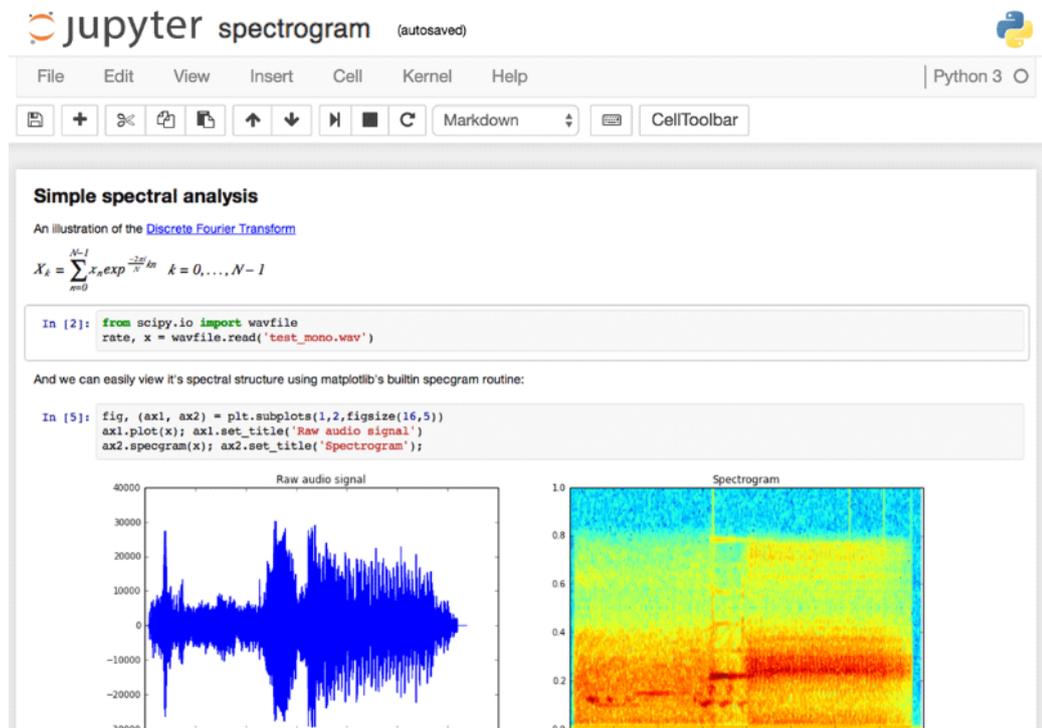


Figura 13 - Jupyter notebook

Fonte: (JUPYTER STEERING COUNCIL, 2018)

4 MATERIAIS E MÉTODOS

Nesse capítulo aborda-se a metodologia e os métodos utilizados na pesquisa e no desenvolvimento do trabalho.

4.1 TIPO DE PESQUISA

A classificação do tipo de pesquisa científica é importante para auxiliar o desenvolvimento de novos métodos científicos, de forma que contribua para a compreensão, análise e discussão de resultados posteriores. Segundo Gil (2010) existem diversos tipos de pesquisas, que são classificadas de acordo com a abordagem, natureza, objetivos da pesquisa e procedimentos técnicos.

A classificação em relação à:

Pesquisa: é do tipo quantitativa. Segundo Kauark, Manhães e Medeiros (2010) a pesquisa quantitativa reconhece os números e as informações para serem classificadas e analisadas. Requer o uso de técnicas estatísticas (porcentagem, média, mediana, moda, desvio padrão, coeficientes, entre outros).

Natureza: a pesquisa é do tipo aplicada, que conforme GIL (2010) é voltada para a aquisição de conhecimentos para aplicação em uma situação específica.

Classificação: é uma pesquisa descritiva, onde é realizada uma descrição de determinada população. Segundo GIL (2010), tem como objetivo identificar relações e associações entre variáveis.

Procedimento técnico: é uma pesquisa operacional, onde são utilizados modelos matemáticos, estatística e algoritmos para ajudar a tomada de decisões (DANTON, 2002).

4.2 A EMPRESA

A empresa, foco deste estudo, está situada no estado do Paraná (Figura

14), sendo de grande porte e atuação no ramo agroindustrial, em especial na produção de frangos de corte. Realiza o abate diário de milhares aves. Atualmente, conta com um grande número de funcionários e associados.

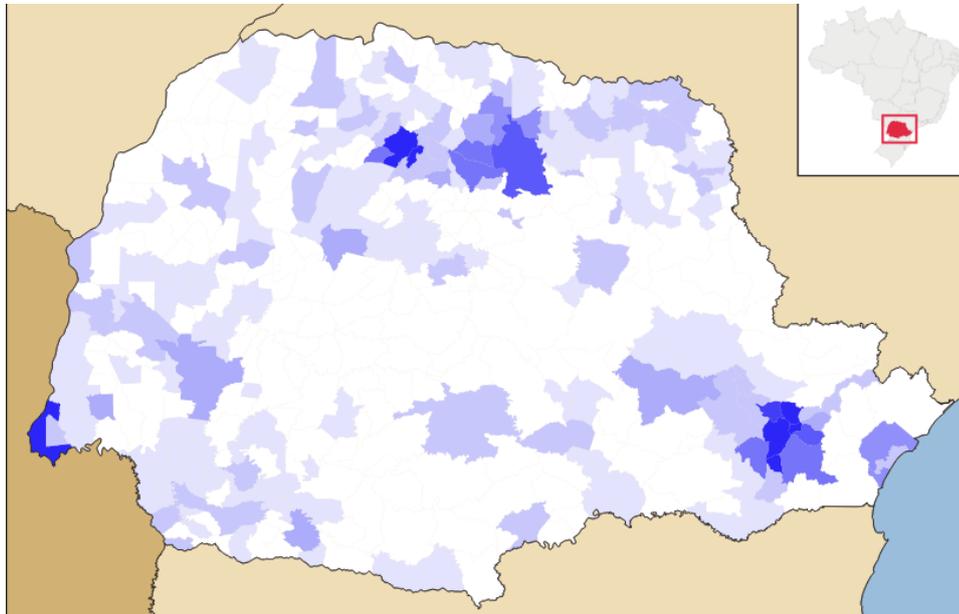


Figura 14 – Estado do Paraná

Fonte: (JÚNIOR, 2012 – CC BY-AS 3.0)

4.3 BASE DE DADOS

A base de dados disponibilizada pela empresa apresenta um histórico de movimentação de 2 anos, contendo as principais variáveis de produção, desde o alojamento até a fase de abate.

A empresa, ao longo da criação de frangos, faz o monitoramento dos seguintes indicadores: Ganho de Peso Diário (GPD), Consumo de ração(CONS), Idade (ID), Conversão Alimentar (CA), Aves Alocadas (AL), Aves Abatidas (AB), Linhagem (LIN) e Peso Médio (PM).

Para previsão do preço dos frangos congelados e resfriados (reais por quilo) utilizaram-se duas bases de dados de 11 anos (2008-2019), 132 meses. As séries históricas são apresentadas na Figura15 (CEPEA, 2019).

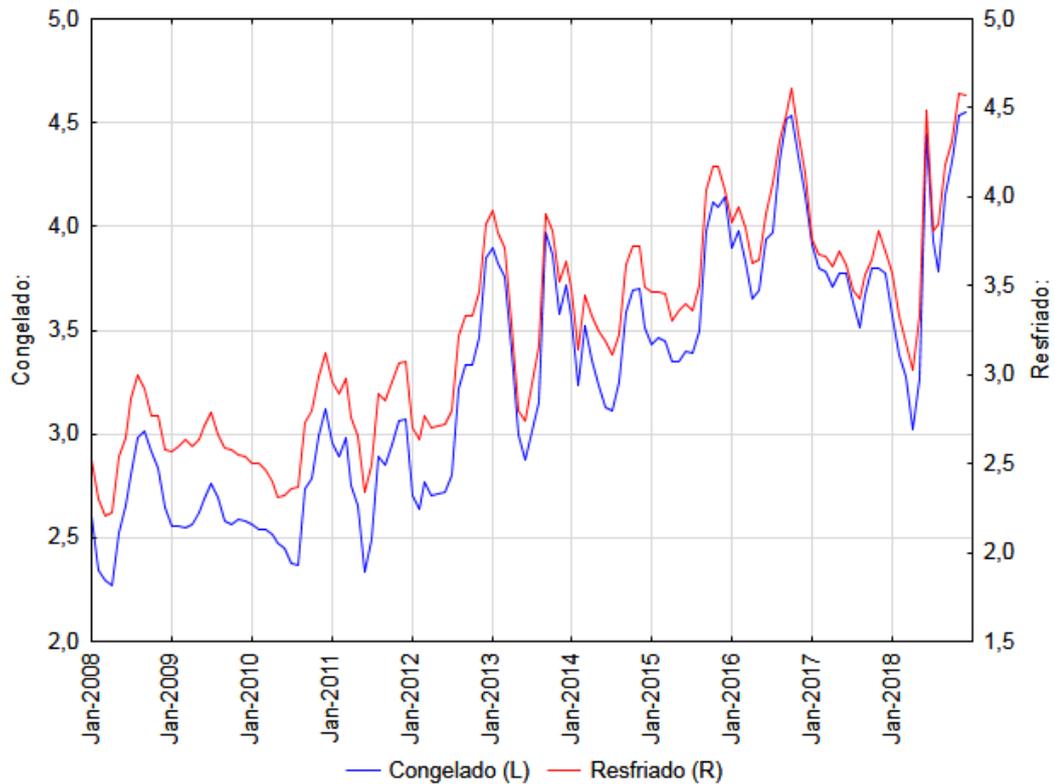


Figura 15 - Preço da carne de frango congelado e resfriado

Fonte: (CEPEA, 2019)

Observam-se das séries, apresentadas acima, uma tendência do aumento do preço (R\$/kg) da carne de frango congelado e resfriado ao longo dos anos.

4.4 TRATAMENTO DOS 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 unificado e livre de inconsistências, contendo informações sobre o Ganho de Peso Diário (GPD), Consumo (CONS), Idade (ID), Conversão Alimentar (CA), Aves Alocadas (AL), Aves

Abatidas (AB), Linhagem (LIN) e o Peso Médio (PM). Na Figura 16 apresenta-se, como exemplo, o gráfico do conjunto de dados da variável Peso Médio, para as linhagens *Coob*, *Coob Fast* e *Coob Slow*.

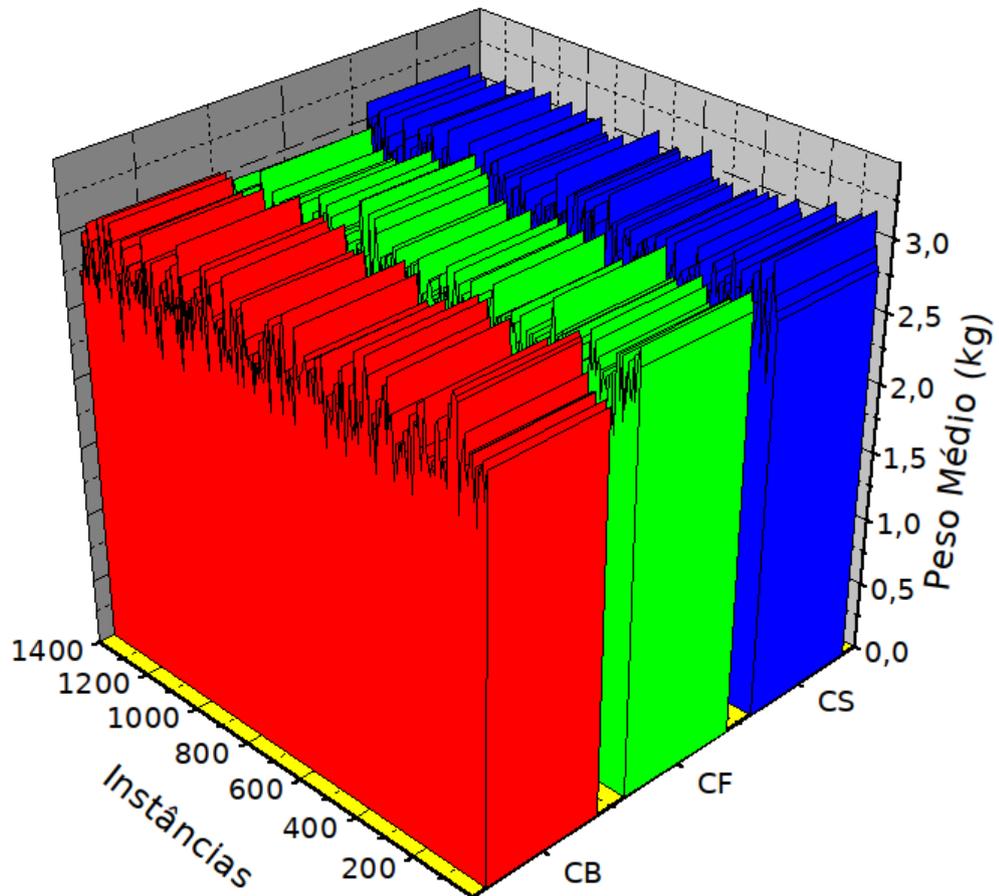


Figura 16 - Peso Médio (kg)

Fonte: O Autor

Onde: Instâncias = número de dados.

Depois de tratar a base de dados, o segundo passo é colocar a base de dados no formato correto para leitura dos dados pela rede neural. Portanto, a nova planilha é exportada no formato *.csv.

Os dados obtidos, da base de dados com os preços dos frangos, já estavam limpos e sem a presença de *outliers* (CEPEA, 2019) (Figura17).

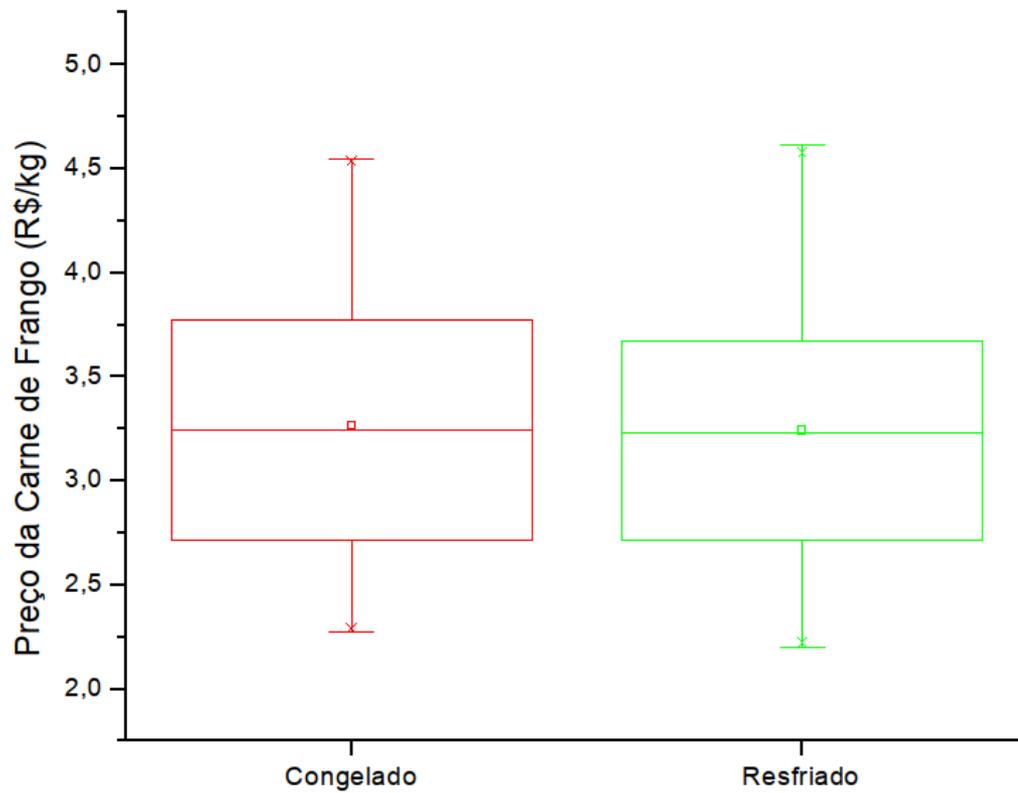


Figura 17 - *Boxplots* – Preço da carne de frango

Fonte: (CEPEA, 2019)

Os dez primeiros registros do conjunto de dados é apresentado na Tabela

1.

Tabela 1 - Dez primeiros registros do arquivo de dados

| Data | Congelado (R\$/kg) | Resfriado (R\$/kg) |
|---------|--------------------|--------------------|
| 2008-01 | 2.605 | 2.519 |
| 2008-02 | 2.34 | 2.305 |
| 2008-03 | 2.291 | 2.215 |
| 2008-04 | 2.273 | 2.224 |
| 2008-05 | 2.526 | 2.542 |
| 2008-06 | 2.656 | 2.648 |
| 2008-07 | 2.804 | 2.865 |
| 2008-08 | 2.979 | 2.998 |
| 2008-09 | 3.011 | 2.917 |
| 2008-10 | 2.916 | 2.766 |

Fonte: (CEPEA, 2019)

4.5 ESTATÍSTICAS SOBRE OS DADOS

Para ilustrar melhor as séries abordadas neste trabalho, obteve-se algumas estatísticas dos dados. As estatísticas são apresentadas no capítulo seguinte, de resultados: Média, Mínimo, Máximo, Desvio padrão e Coeficiente de variação.

4.6 ÍNDICE DE EFICIÊNCIA PRODUTIVA E PESO MÉDIO

A agroindústria 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, ele vem aumentando significativamente nos últimos anos devido às melhorias nos mais diferentes segmentos da produção como nutrição, genética, sanidade, manejo, ambiência, entre outros (SOBRINHO, 2010; BASTIANI, 2017). O IEP leva em conta a Conversão Alimentar (CA), o Ganho de Peso Diário (GPD) e a Viabilidade do lote (Aves Abatidas (ABAT)/Aves Alocadas (ALOC)). O IEP é obtido por meio da Equação 3:

$$IEP = \frac{\text{GanhodePesoDiário (GPD)} \times \text{Viabilidade (VIAB)}}{\text{ConversãoAlimentar(CA)}} \times 100 \quad (3)$$

Onde:

$$\text{Peso Médio (PM)} = \frac{\text{Peso total do lote}}{\text{Aves Entregues (ABAT)}} \quad (4)$$

$$\text{Ganho de Peso Diário (GPD)} = \frac{\text{Peso Médio (PM)}}{\text{Idade (ID)}} \quad (5)$$

$$\text{Convers\~{a}o Alimentar (CA)} = \frac{\text{Consumo total de r\~{a}o\~{a}o (CONS)}}{\text{Peso total do lote}} \quad (6)$$

Al\~{e}m do IEP, o Peso M\~{e}dio (PM) \u00e9 outro \u00edndice monitorado pela agroind\u00fastria. Este \u00edndice \u00e9 tamb\u00e9m importante na adequa\u00e7\~{a}o dos equipamentos automatizados de uma agroind\u00fastria de abate de frangos de corte. Portanto, as empresas av\u00edcolas buscam uma uniformidade do peso do produto, j\~{a} que uma baixa uniformidade prejudica o desempenho do processo, a integridade do produto, o cumprimento das especifica\u00e7\~{o}es dos clientes e o aumento de descarte das pe\u00e7as (BASTIANI, 2017).

4.7 RECURSOS

A implementa\u00e7\~{a}o dos algoritmos foi feita com o suporte do *Jupyter Notebook* e com a linguagem de programa\u00e7\~{a}o Python. As bibliotecas de aprendizado de m\~{a}quina: *Scikit-learn* e *Keras* s\~{a}o tamb\u00e9m utilizadas. *Scikit-learn* \u00e9 uma biblioteca de aprendizado de m\~{a}quina, para a linguagem Python, que inclui v\~{a}rios algoritmos de classifica\u00e7\~{a}o, regress\~{a}o e agrupamento. *Keras* \u00e9 uma biblioteca de alto n\u00edvel, escrita em Python.

O *framework* de *Deep Learning Keras*, proporciona ferramentas para constru\u00e7\~{a}o e treinamento de redes neurais de alto n\u00edvel, permitindo usar como *backend* a ferramenta *TensorFlow*. O *TensorFlow* \u00e9 uma biblioteca Python para computa\u00e7\~{a}o num\u00e9rica criada pela Google. O *framework Keras*, baseado na simplicidade, tem estrutura modular e permite programar uma rede neural com poucas linhas de c\u00f3digo, sendo vers\~{a}til e de f\~{a}cil utiliza\u00e7\~{a}o. *Keras* conta com v\~{a}rios algoritmos de aprendizagem assim como fun\u00e7\~{o}es de ativa\u00e7\~{a}o e avalia\u00e7\~{a}o para os modelos implementados. Foi criada em 2015 pelo Engenheiro da Google Fran\u00e7ois Chollet e em 2017 come\u00e7ou a fazer parte da biblioteca *Tensor Flow* (MENEZES, 2014).

O c\u00f3digo da rede neural LSTM implementado em *Keras* \u00e9 apresentado na Figura 18.

```
# Model
model = Sequential()
model.add(LSTM(256, input_shape=(layers[1],layers[0]),
return_sequences=True))
model.add(Dropout(0.2))
model.add(LSTM(128))
model.add(Dropout(0.2))
model.add(Dense(3,activation = 'linear'))
model.compile(optimizer=Adam(lr=0.002), loss='mse')
```

Figura 18 - Código em KERAS da rede neural LSTM

Fonte: O Autor

Os algoritmos foram executados em um *notebook* com o sistema Ubuntu 18.04. O *notebook* conta com um processador Intel i7, 2,27GHz e 16GB de memória RAM.

4.8 NORMALIZAÇÃO

Os dados utilizados nas redes neurais, MLP e LSTM, devem estar dentro da escala da função de ativação utilizada pela rede. A técnica de normalização é geralmente aplicada como parte da preparação dos dados de uma rede neural. O objetivo da normalização é alterar os valores das colunas numéricas no conjunto de dados para usar uma escala comum, sem distorcer a diferença nos intervalos de valores ou perder informações (BINOTI, 2010).

Neste trabalho, a normalização dos dados, para o intervalo [-1,1], foi realizada por meio da função *MinMaxScaler()* da biblioteca *Scikit-learn*.

4.9 PARÂMETROS – REDES NEURASIS

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.

Como critério de parada utilizou-se a função do *Keras EarlyStopping*(*monitor='loss'*, *patience=50*, *mode='min'*). Onde: *loss* – é a medida de desempenho desejada, no caso o Erro Médio Quadrático; *patience* – é um *delay* para o acionador da parada, define-se nesse caso um número de épocas nas quais não se vê melhorias; *mode* – define-se o objetivo da métrica se é diminuir (min) ou aumentar (max).

Utilizou-se entre as camadas a técnica de regularização *dropout*, que faz com que os neurônios sejam excluídos aleatoriamente do processo de treinamento para evitar sobreadaptação (*overfitting*), no modelo de previsão, aumentando a generalização.

4.10 MÉTRICAS

Segundo Passari (2003), para se avaliar métodos de previsão existem diferentes critérios como: habilidade do analista, facilidade de uso, acurácia, custo; facilidade de interpretação, entre outros.

Neste trabalho, os modelos obtidos foram avaliados pelos parâmetros: coeficiente de correlação (*Correlation Classification*), erro médio quadrático (*Mean Squared Error*) e raiz quadrada do erro médio quadrático (*Root Mean Squared Error*) – Tabela 2.

Tabela 2 - Métricas para avaliação

| | Valor Perfeito | Observações |
|---------------------------------------|-----------------------|---|
| <i>Correlation Coefficient</i> | CC = 1 | Mede o grau de associação linear entre os dados previstos e observados. |
| <i>Mean Squared Error</i> | MSE = 0 | É uma forma de avaliar a diferença entre um estimador e o verdadeiro valor da quantidade estimada. |
| <i>Root Mean Squared Error</i> | RMSE = 0 | Raiz do erro médio quadrático da diferença entre a predição e o valor real. É uma das medidas mais comuns para erro em trabalhos sobre modelos de previsão. |

Fonte: O Autor

Para MSE e RMSE quanto mais próximas da realidade forem as previsões, menores são os seus valores, de forma que elas dão ao analista critérios objetivos para julgar os resultados obtidos e comparar diferentes modelos.

4.11 MÉTODOS DE FRAGMENTAÇÃO

No desenvolvimento de modelos de RNA os dados disponíveis são aleatoriamente particionados em conjuntos de treinamento, teste e validação. O conjunto de treinamento é utilizado para estimar parâmetros do modelo. Durante o processo de treinamento uma função erro é avaliada no conjunto de teste. O conjunto de validação é utilizado como uma fonte de dados independente para avaliar a habilidade de generalização da rede.

Para criar os subconjuntos de dados, de treinamento e teste, foram usados 4500 lotes do banco de dados da agroindústria. Sendo 1500 da linhagem *Coob*, 1500 da linhagem *Coob Fast* e 1500 da linhagem *Coob Slow*. Neste trabalho utilizaram-se dois métodos de fragmentação: o método *Holdout* onde a base de dados foi dividida com 66% dos dados para treinamento dos algoritmos e 34% para teste e 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 testes, enquanto as demais são utilizadas para o treinamento (WITTEN; FRANK, 2005).

Pode-se considerar o procedimento geral, da validação cruzada, como (Figura 19):

- a) “Embaralhe” aleatoriamente o conjunto de dados;
- b) Divida o conjunto de dados em k grupos (Figura 19 – 5 grupos);
- c) Para cada grupo pegue um conjunto de dados de teste e treinamento (Figura 19 – 4 grupos de treino e 1 grupo de teste);
- d) Treine o modelo e teste com o conjunto de teste;
- e) Guarde o parâmetro de avaliação e descarte o modelo;

- f) Rode os k modelos (Figura 19 – 5 iterações) e escolha o modelo com melhor parâmetro de avaliação.



Figura 19 – Validação cruzada

Fonte: O Autor

Para validação dos modelos, implementados neste trabalho, utilizou-se um conjunto de 150 lotes de frangos que não participaram das fases de treinamento e teste.

5 RESULTADOS

Inicialmente, neste trabalho, realizou-se uma análise descritiva dos dados para as três linhagens (Tabela3).

Tabela 3 - Análise descritiva de dados – Agroindústria

| 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 (kg) | | 2,81 | 2,378 | 3,26 | 0,165 | 5,872 |
| ID (dias) | | 45,38 | 42 | 51 | 1,556 | 3,429 |
| GPD (g) | | 61,88 | 54,15 | 69,61 | 2,86 | 4,622 |
| CA | | 1,65 | 1,518 | 1,79 | 0,051 | 3,091 |
| CONS (kg) | | 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 (kg) | | 2,82 | 2,408 | 3,25 | 0,15 | 5,319 |
| ID (dias) | | 45,66 | 42 | 50 | 1,214 | 2,659 |
| GPD (g) | | 61,65 | 54,44 | 69,33 | 2,699 | 4,378 |
| CA | | 1,66 | 1,523 | 1,79 | 0,049 | 2,952 |
| CONS (kg) | | 4,66 | 3,879 | 5,47 | 0,271 | 5,815 |
| CS | | | | | | |
| ALOC | 1650 | 16395,4 | 7500 | 18700 | 2103,52 | 12,83 |
| ABAT | | 15852,6 | 6962 | 18405 | 2042,55 | 12,885 |
| PM (kg) | | 2,84 | 2,401 | 3,25 | 0,153 | 5,387 |
| ID (dias) | | 45,68 | 42 | 49 | 1,291 | 2,826 |
| GPD (g) | | 62,21 | 54,13 | 69,73 | 2,703 | 4,345 |
| CA | | 1,65 | 1,518 | 1,79 | 0,05 | 3,03 |
| CONS (kg) | | 4,72 | 9,897 | 5,47 | 0,276 | 5,847 |

Fonte: O Autor.

Observou-se dos dados, apresentados na Tabela 3, 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 3, e dados obtidos da Tabela 3, 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 3, que os dados apresentam bons coeficientes de variação. Segundo Pimentel (2009), 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.

Nas Figuras 20 e 21 apresentam-se, em termos de visualização, os *boxplots* e os gráficos de dispersão dos valores do Peso Médio e do Índice de Eficiência produtiva para as linhagens *Coob* (CB), *Coob Fast* (CF) e *Coob Slow* (CS).

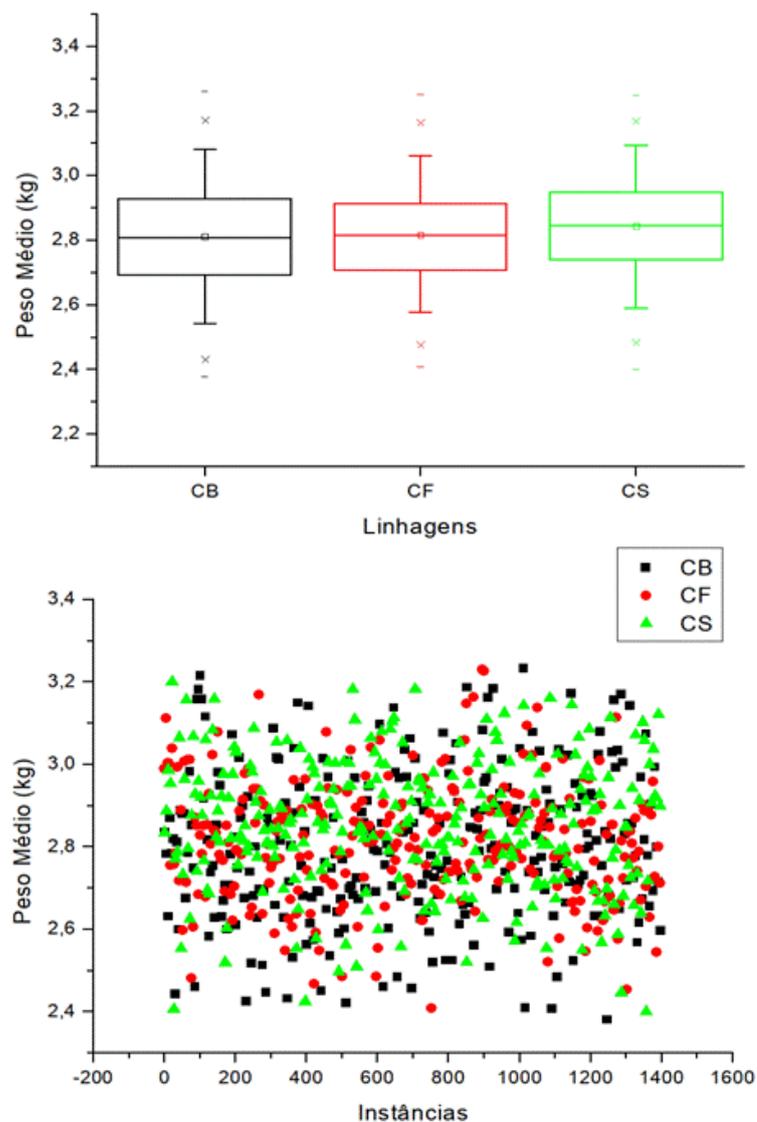


Figura 20 - Boxplots e gráfico de dispersão – PM

Fonte: O Autor.

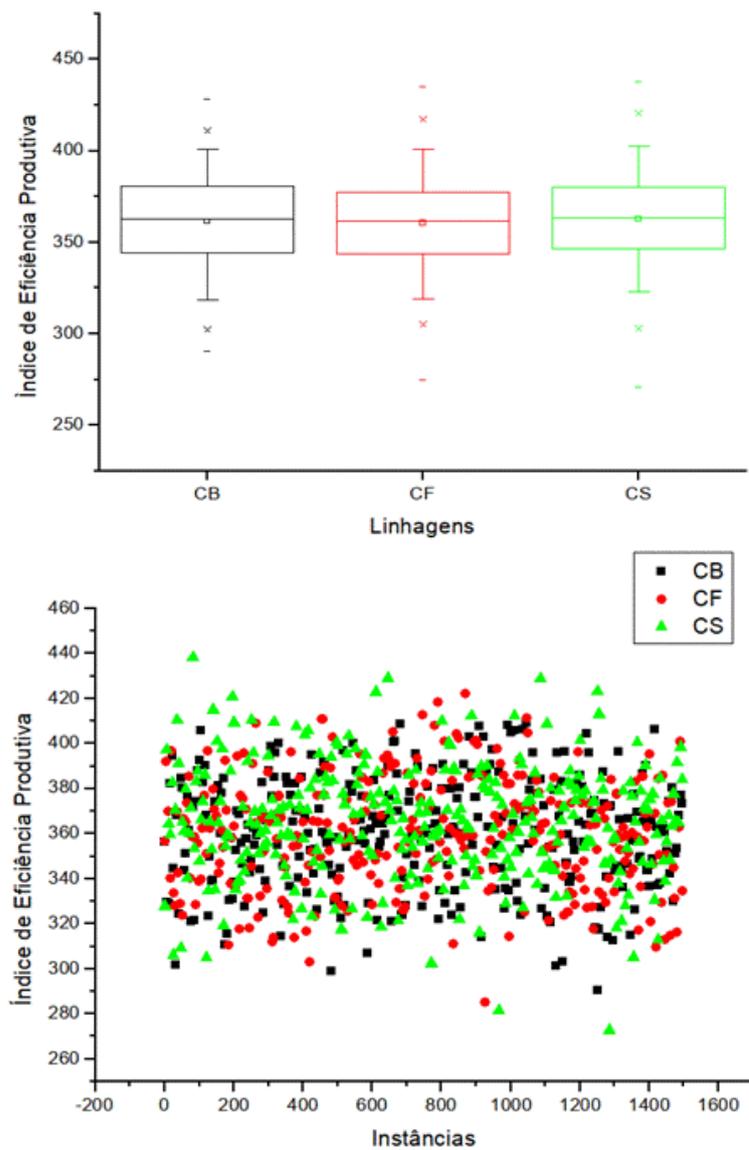


Figura 21 - Boxplots e gráfico de dispersão – IEP

Fonte: O Autor.

Observa-se, dos gráficos apresentados nas Figuras 20 e 21, devido a dispersão dos dados, que não existem correlação entre as observações das amostras.

5.1 SELEÇÃO DE ATRIBUTOS

A correlação é uma técnica popular para selecionar atributos relevantes em um banco de dados. Nesta técnica pode-se calcular a correlação entre cada atributo e a

variável de saída e utilizar 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, 2017). Na Tabela 4 apresentam-se os resultados obtidos para as variáveis de resposta: índice de Eficiência Produtiva e Peso Médio.

Tabela 4 - Classificação dos atributos

| 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 |

Fonte: O Autor.

As variáveis de entrada relevantes para cada uma das variáveis de resposta são apresentadas na Tabela 5.

Tabela 5 - Variáveis de entrada e saída para os algoritmos

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

Fonte: O Autor.

5.2 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 22).). O número de neurônios da camada oculta (nn) foi definido através da Equação 7:

$$nn = \frac{nCamadaEntrada + nCamadadeSaída}{2} \quad (7)$$

As equações de regressão linear obtidas, utilizando a função `linearregression()` da biblioteca *Scikit-learn* do Python, são apresentadas nas Equações 8 e 9.

$$PM = 0,0454GPD + 0,00284CONS + 0,0612ID - 2,796 \quad (8)$$

$$IEP = 10,361GPD - 48,295CA - 59,978CONS + 3,655VIAB + 6,09ID - 550,09 \quad (9)$$

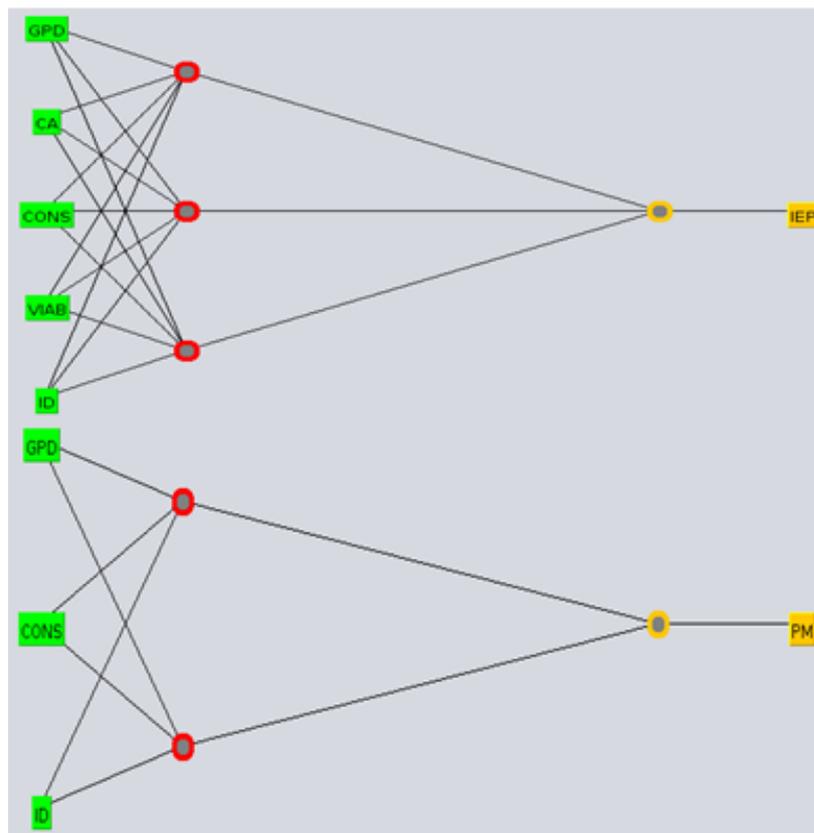


Figura 22 - Redes MLP 5-3-1 e MLP 3-2-1

Fonte: O Autor.

Na Figura 23 são apresentadas as curvas de aprendizagem para a variáveis IEP e PM. Observa-se das figuras a estabilidade na convergência das curvas de treino e teste para as duas variáveis em estudo.

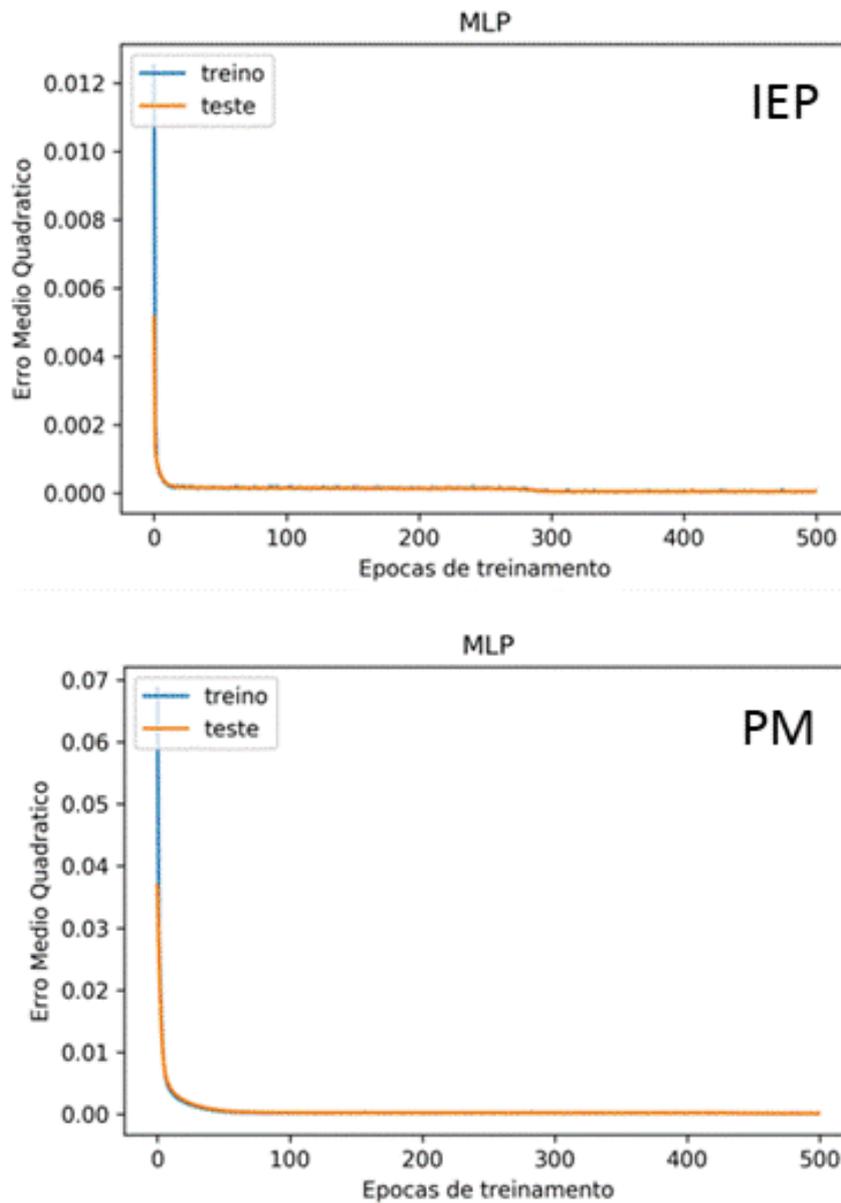


Figura 23 - Curvas de aprendizagem de treino e teste – IEP e PM

Fonte: O Autor.

A Tabela 6 apresenta os resultados obtidos, dos dois algoritmos, para as variáveis de resposta Índice de Eficiência Produtiva (IEP) e Peso Médio (PM).

Tabela 6 - Resultados da aplicação dos algoritmos MLP e LR

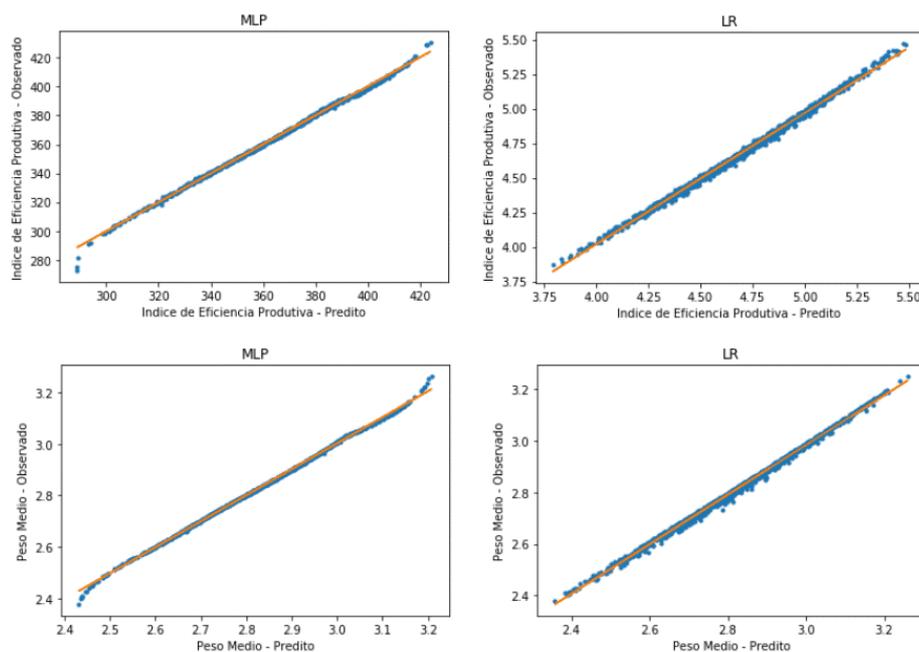
| | IEP | | PM | |
|--|--------|---------|---------|---------|
| | LR | MLP | LR | MLP |
| Coeficiente de Correlação | 0,9787 | 0,9989 | 0,9923 | 0,9991 |
| Erro médio quadrático | 0,006 | 0,00002 | 0,00025 | 0,00002 |
| Raiz quadrada do erro médio quadrático | 0,024 | 0,004 | 0,016 | 0,005 |

Fonte: O Autor.

Verifica-se, por meio dos resultados apresentados na Tabela 6, que os dois algoritmos apresentam praticamente os mesmos resultados de coeficiente de correlação. As análises dos erros permitem verificar que os melhores resultados foram obtidos usando o algoritmo MLP para as variáveis Peso Médio (PM) e Índice de Eficiência Produtiva (IEP).

Dados Preditos *versus* Dados Observados:

Na sequência, avaliou-se a dispersão dos valores preditos pelos dois algoritmos em relação aos valores observados para as duas variáveis de resposta (Figura 24).

**Figura 24 - Dados preditos em função de dados observados**

Fonte: O Autor.

Observa-se 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.

Teste dos Modelos:

Para validar os modelos compararam-se resultados obtidos dos algoritmos com resultados obtidos de 150 lotes de frangos que não participaram da fase de teste e treinamento (Figura 25).

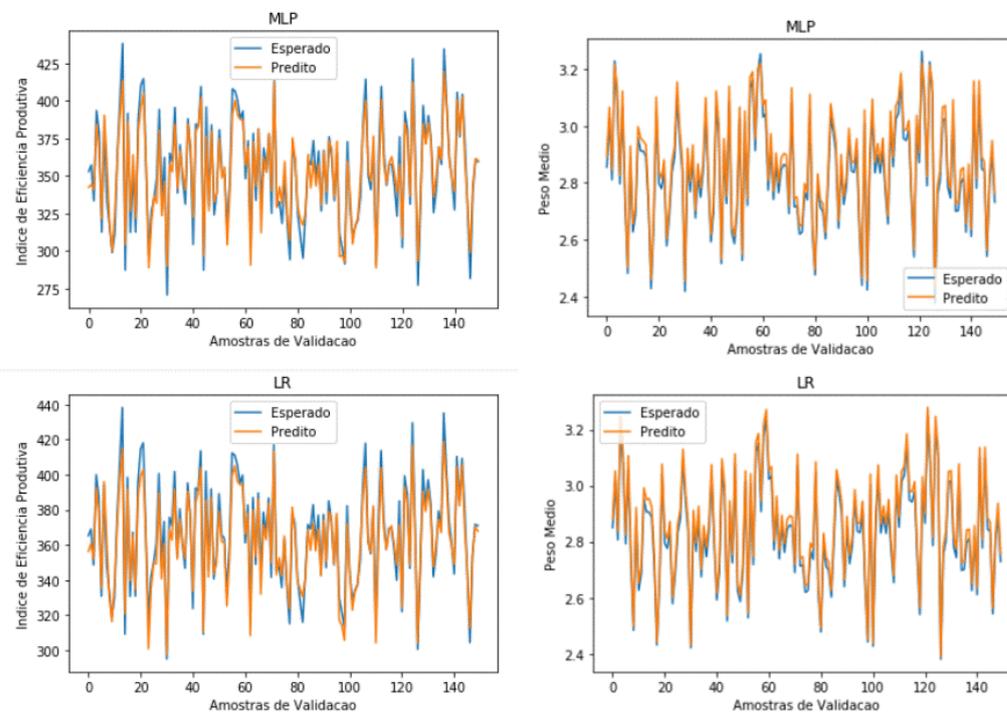


Figura 25 - Dados preditos em função de dados observados – Conjunto de validação: 150 lotes

Fonte: O Autor.

Pode-se observar, por meio dos gráficos apresentados na Figura 25, que existe uma boa aproximação entre os resultados reais e os previstos pelos dois algoritmos.

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 previstas pela rede neural, para as duas variáveis em estudo (IEP e PM) (Tabela 7).

Tabela 7 - Análise de variância

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

Fonte: O Autor.

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. Na Figura 26 apresentam-se os *boxplots* dos dados previstos e observados para duas variáveis.

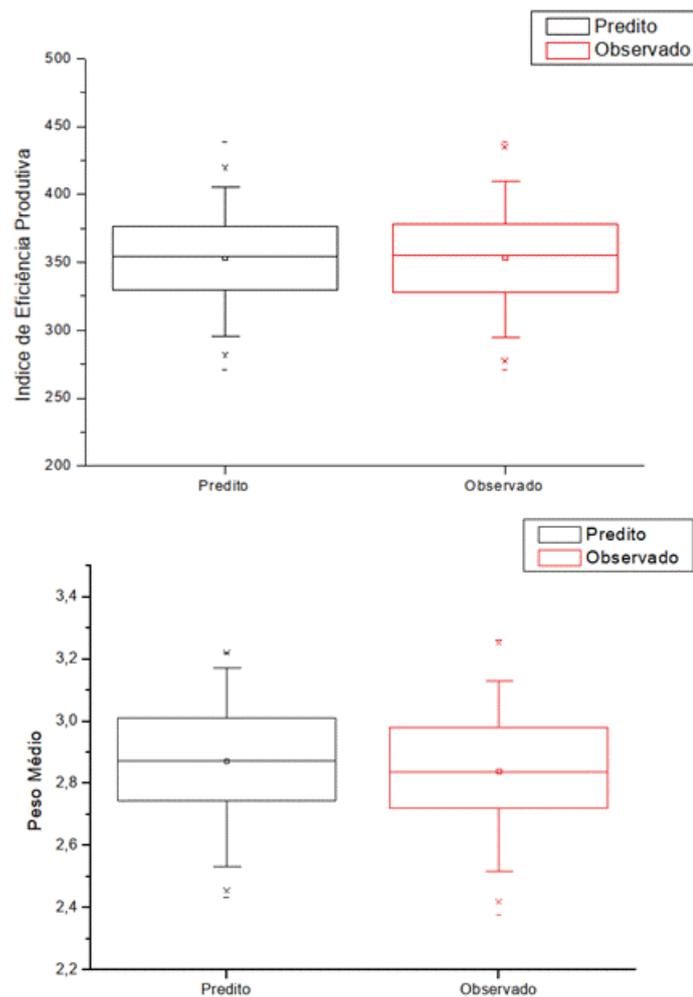


Figura 26 - Boxplots – IEP e PM

Fonte: O Autor.

Métodos de Fragmentação:

É relevante observar que o método *Cross-validation* apresentou melhores resultados, em termos de erro, que o método *Holdhout* para a variável PM (Tabela 8).

Tabela 8 - Resultados da aplicação do algoritmo MLP – *Cross-validation* e *Holdhout*

| Métricas | PM | |
|--|-------------------------------|-----------------------|
| | MLP - <i>Cross-validation</i> | MLP - <i>Holdhout</i> |
| Coeficiente de Correlação | 0,9991 | 0,9608 |
| Erro médio quadrático | 0,00002 | 0,0015 |
| Raiz quadrada do erro médio quadrático | 0,005 | 0,037 |

Fonte: O Autor.

Bastiani (2017) e Reali (2004) obtiveram, por meio dos softwares NeuroShellPredictor e WEKA, muito boas previsões para as variáveis PM e IEP de frangos de corte. Sendo que Bastiani (2017) analisou somente as linhagens *Coob* e *Coob Slow*.

5.3 REDES RECORRENTES

Preço da carne de frango:

Diante da importância do setor da carne de frango no varejo, sobretudo em razão do consumo por grande parte das famílias brasileiras, torna-se importante fazer uma análise, no maior estado consumidor nacional de frango, baseada num modelo de previsão que permita observar as tendências de mercado.

Na Tabela 9 apresenta-se a análise descritiva dos dados do preço da carne frango congelada e resfriada.

Tabela 9 - Análise descritiva do preço da carne de frango

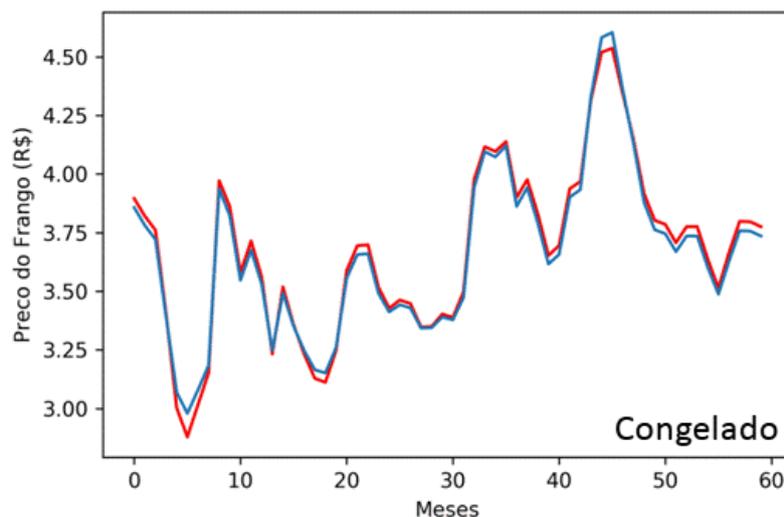
| | Congelado (R\$/kg) | Resfriado (R\$/kg) |
|------------------------------|--------------------|--------------------|
| Quantidade | 132 | 132 |
| Média | 3,258 | 3,238 |
| Mínimo | 2,273 | 2,202 |
| Máximo | 4,547 | 4,614 |
| Desvio Padrão | 0,594 | 0,6 |
| Coefficiente de Variação (%) | 18,2 | 18,5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

Fonte: O Autor.

Pode-se observar da Tabela 9 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. 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.

Rede LSTM:

Inicialmente, apresenta-se na Figura 27 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 27 - Resultados das previsões – 60 meses**

Fonte: O Autor.

Observa-se que em azul apresentam-se os dados da série temporal original. Na cor vermelha apresentam-se as previsões da rede LSTM.

Por meio dos resultados apresentado na Figura 27 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 Figura 28, em termos de visualização, e na Tabela 10, em termos quantitativos, as previsões, do preço do quilo de frango congelado e resfriado, para os três primeiros meses de 2019.

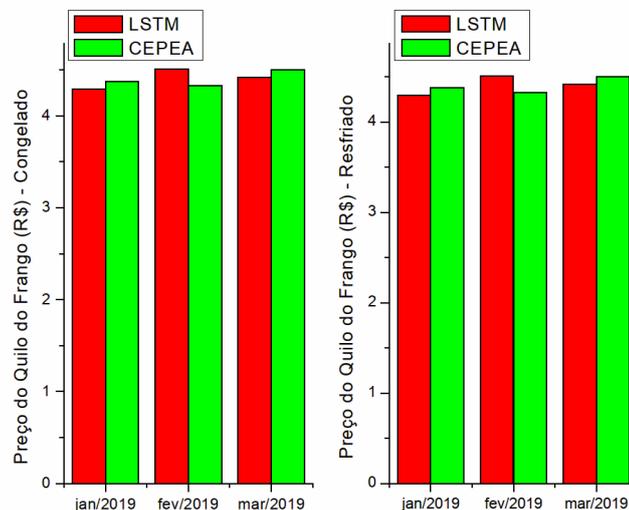


Figura 28 - Preço do quilo do frango – congelado e resfriado

Fonte: O Autor.

Tabela 10 - 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 |

Fonte: O Autor.

Por meio dos resultados apresentados, na Tabela 10 e na Figura 28, conclui-se que os resultados das previsões estão muito próximos aos do Centro de Estudos Avançado de Economia Aplicada (CEPEA). Observou-se também, nestas previsões, que a rede LSTM obteve um bom desempenho com os dados utilizados (Tabela 11).

Tabela 11 - Métricas

| Métrica | Congelado | Resfriado |
|---------|-----------|-----------|
| MSE | 0,01 | 0,015 |
| RMSE | 0,102 | 0,122 |

Fonte: O Autor.

Nas Figuras 29 e 30 apresentam-se as evoluções das séries temporais do preço 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.

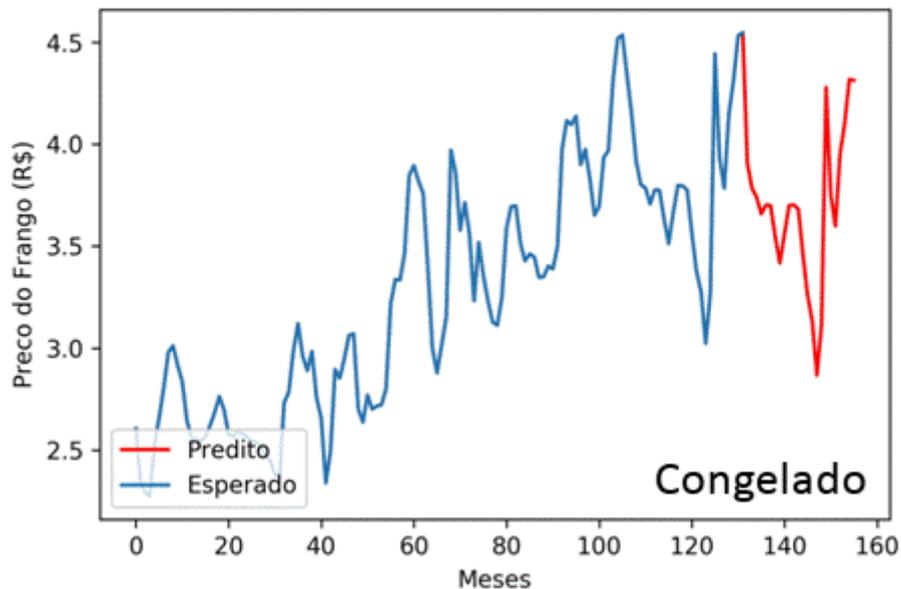


Figura 29 - Resultados das previsões do preço do frango congelado

Fonte: O Autor

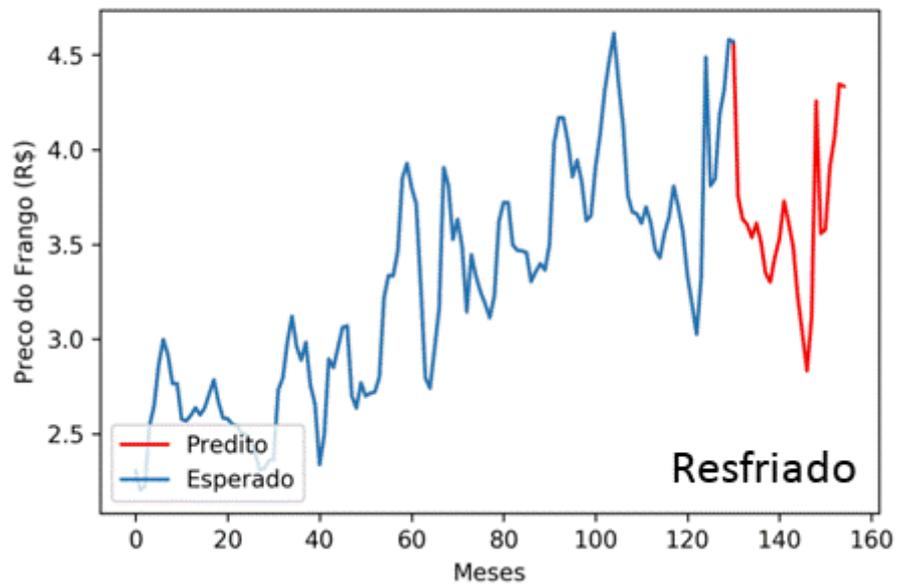


Figura 30 - Resultados das previsões do preço do frango resfriado

Fonte: O Autor

6 CONCLUSÃO

Este trabalho teve por objetivo utilizar modelos de redes neurais artificiais *multilayer perceptron* (MLP) e regressão linear múltipla (LR) para análise e previsão de variáveis produtivas de frangos corte. Analisou-se, também, a aplicabilidade de redes neurais recorrentes (LSTM) na previsão futura do preço (R\$/kg) do quilo do frango congelado e resfriado.

A empresa, em estudo, forneceu um banco de dados com um histórico de movimentação de 2 anos, contendo dados desde o alojamento até a fase de abate. Neste estudo, utilizaram-se as seguintes variáveis: Ganho de Peso Diário, Consumo, Idade, Conversão Alimentar, Aves Alocadas, Aves Abatidas, Linhagem, Peso Médio e Índice de Eficiência Produtiva. Utilizou-se também, neste trabalho, um banco de dados de 11 anos, com preços do quilo do frango congelado e resfriado, negociado no atacado da região da grande São Paulo.

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). Estes 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 significativa 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.

REFERÊNCIAS

AMRAEL, S.; MEHDIZADEH, S. A.; SALARI, S. Broiler weight estimation based in machine vision an artificial neural network. **British Poultry Science**. 58(2), 200-205, 2017.

Associação Brasileira de Proteína Animal (ABPA). **Relatório Anual Completo**. Disponível em:< http://abpa-br.com.br/files/RelatorioAnual_UBABEF_2015_DIGITAL.pdf>. Acesso em: 12 outubro 2018.

AZARIAS, P. Aplicação de mineração de dados para geração do conhecimento: um experimento prático. **InAnais...** V Congresso Nacional de Excelência em Gestão. Niterói RJ, 2009.

BASTIANI, M. **Aplicação de controle estatístico de processos e algoritmos de mineração de dados na gestão de frangos de corte**. [Dissertação]. Medianeira: Universidade Tecnológica Federal do Paraná, 2017.

BINOTI, M. L. M. S. **Rede neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. [Dissertação]. Viçosa: Universidade Federal de Viçosa; 2010.

BRAGA, A. 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, 2019.

CAMILO, C. O.; SILVA, J. C. **Mineração de Dados: Conceitos, Tarefas, Métodos e Ferramentas**. Disponível em: < http://www.inf.ufg.br/sites/default/files/uploads/relatorios-tecnicos/RT-INF_001-09.pdf >. Acesso em: 12 outubro 2019.

CAMPOS, P. A. C. Aplicação do modelo ARIMA para previsão do preço do frango inteiro resfriado no grande atacado do estado de São Paulo. **In...** XIII Congresso Brasileiro de Custos. Belo Horizonte MG, 2006.

CENTRO DE ESTUDOS AVANÇADOS EM ECONOMIA APLICADA (CEPEA). **Agronegócio**. Piracicaba, 2019. Disponível em: < <https://www.cepea.esalq.usp.br/br> >. Acesso em: 5 de junho 2019.

CORRÊA, H. L.; CORRÊA, C. A. **Administração de produção e operações**. 3. ed. São Paulo: Atlas, 2012.

CUNHA, C. C. **Avaliação de desempenho da produção de frangos de corte no Brasil utilizando análise de envoltória de dados e índice de malmquist**. [Dissertação]. Brasília: Universidade de Brasília, 2014.

DANTON, G. **Metodologia Científica**. Minas Gerais: *Virtual Books Online* M&M Editores Ltda, 2002.

DVOJATZKI, P. **Identificação e avaliação de projetos de investimentos para redução dos índices de condenações de frangos de corte**. [Dissertação]. Cascavel: Universidade Estadual do Oeste do Paraná, 2017.

EMAN, J. C.; HADEEL, A. O. NIEMAH, I. O. *JPT: A simple java-python translator*. **Computer Applications: An International Journal (CAIJ)**, v. 5, n. 2, 2018.

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária: **Linhagens**. 2017. Disponível em: < https://www.agencia.cnptia.embrapa.br/gestor/frango_de_corte/arvore/CONT000fc68q25k02wx5eo0a2ndxy8lyc3jr.html > Acesso em: 01 de maio de 2017.

GIL, A. C., **Como elaborar projetos de pesquisa**. 5 ed., São Paulo: Atlas, 2010.

GOLDSCHMIDT, R.; PASSOS E. **Data mining: um guia prático, conceitos, técnicas, ferramentas, orientações e aplicações**. São Paulo: Elsevier; 2005.

GRAVES A. Towards end-to-end speech recognition with recurrent neural networks. **In...** Proceedings of the 31st International Conference on Machine Learning (ICML-14), Beijing, China, 2014.

HAYKIN, S. **Neural networks: a comprehensive foundation**. New Delhi: Pearson Prentice Hall, 2005.

HAN, J; KAMBER, M. **Data Mining: Concepts and Techniques**. Elsevier, 2006.

JOHASEN, S. V.; BENDTSEN, J. D.; MOGENSEN, J. Broiler slaughter weight forecasting using dynamic neural network models. **In...** IEEE 6th International Conference (ICIEA), Tokio JP, 2019.

JÚNIOR, J. G. G; BENTO, E. F.; SOUZA, A. F. Diagnóstico da realidade dos criatórios de aves na comunidade base física - Ipanguaçu/RN. **Revista Holos**. 4(1), 120-126, 2009.

JÚNIOR, M. E. O. **Mapa do estado do Paraná**. 2012 Disponível em: <https://upload.wikimedia.org/wikipedia/commons/3/38/PR_DensidadePopulacional.svg>. Acesso em: 20 abr. 2020. CC BY-AS 3.0

JUPYTER STEERING COUNCIL. **Project Jupyter**. Disponível em <<http://jupyter.org/about>>, Acesso em: 01/010/2018.

KAUARK, F.; MANHÃES, F. C.; MEDEIROS, C. H. **Metodologia da pesquisa**. Itabuna: Via Litterarum Editora, 2010.

LUSTOSA, L. **Planejamento e controle da produção**. Rio de Janeiro: Elsevier, 2008.

MENEZES, N. N. C. **Introdução a programação com Python**. São Paulo: Novatec, 2014.

MOREIRA, D. A. **Administração da produção e operações**. 2 ed. São Paulo: Cengage Learning, 2011.

MORETTIN, P. A.; TOLOI, C.M. C. **Análise de séries temporais**. São Paulo: Edgard Blucher, 2004.

OLAH, C. **Understanding LSTM Networks**. 2015 Disponível em: <<https://colah.github.io/posts/2015-08-Understanding-LSTMs/>>. Acesso em: 15 abr. 2019.

PASSARI, A. F. L. **Exploração de Dados Atomizados para Previsão de Vendas no Varejo Utilizando Redes Neurais**. São Paulo: USP, 2003.

PIACENTI, C. A. O preço do frango de corte: Evolução e tendências no Brasil. **Cadernos de Economia**. 21(11), 79-94, 2007.

PIMENTEL, F. **Curso de estatística experimental**. 15. ed. Piracicaba: ESALQ, 2009.

REALI, E. H. **Utilização de inteligência artificial - (Redes Neurais Artificiais) no gerenciamento da produção de frangos de corte**. [Dissertação]. Porto Alegre: Universidade Federal do Rio Grande do Sul, 2004.

RICHETTI, A.; SANTOS, A. C. O sistema integrado de produção de frango de corte em Minas Gerais: uma análise sob ótica da ECT. **Organizações Rurais e Agroindustriais**, Lavras, v. 2, n. 2, p. 34-43, 2010.

RIZZI, A. T. **Mudanças tecnológicas e reestruturação da indústria agroalimentar: o caso da indústria de frangos no Brasil**. [Tese]. Campinas: Universidade Estadual de Campinas, 1993.

SEBASTIAN, S. Performance evaluation by artificial neural network using WEKA. **International Research Journal of Engineering and Technology**, vol. 3, 2016.

SILVA, R. A. **Estudo preliminar da aplicação de redes neurais no sistema de controle de temperatura em uma planta didática**. [Trabalho de Conclusão de Curso]. Niteroi: Universidade Federal Fluminense; 2015.

SONGINI, M. L. Put in Plain Language: The high portable, object-oriented Python language moves into enterprise application development. **Computer world**, 2005.

TUBINO, D. F. **Planejamento e controle da produção: teoria e prática**. 2 ed. São Paulo: Atlas, 2009.

WITTEN, I. H.; FRANK, E. **Data Mining: practical machine learning tools and techniques**. São Francisco: Elsevier, 2005.

VOILA, M.; TRICHES, D. A cadeia de carne de frango: uma análise dos mercados brasileiro e mundial de 2002 a 2010. **Instituto de Pesquisas Econômicas e Sociais**, n.44, 2012.

UBA, União Brasileira de Avicultura. **Protocolo de Boas Práticas de Produção de Frangos**. São Paulo: UBA., 2008.

ZAO, Z. LSTM network: a deep learning approach for short-term traffic forecast. **IET Intelligent Transport Systems**. 11(2), 68-75, 2017.