

## APLICAÇÃO DE ALGORITMOS DE MINERAÇÃO DE DADOS NA GESTÃO DA PRODUÇÃO DE FRANGOS DE CORTE

### APPLICATION OF DATA MINING ALGORITHMS IN THE MANAGEMENT OF THE BROILER PRODUCTION

Miliano de Bastiani<sup>1</sup>; José Airton A. dos Santos<sup>2</sup>; Carla Adriana Pizarro Schmidt<sup>3</sup>; Gloria Patrícia Lopez Sepulveda<sup>4</sup>

<sup>1</sup>Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio- PPGTCA  
Universidade Tecnológica Federal do Paraná – UTFPR – Medianeira/PR - Brasil  
[milianodebastiani@gmail.com](mailto:milianodebastiani@gmail.com)

<sup>2</sup>Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio- PPGTCA  
Universidade Tecnológica Federal do Paraná – UTFPR – Medianeira/PR - Brasil  
[airton@utfpr.edu.br](mailto:airton@utfpr.edu.br)

<sup>3</sup>Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio- PPGTCA  
Universidade Tecnológica Federal do Paraná – UTFPR – Medianeira/PR - Brasil  
[carlaschmidt@utfpr.edu.br](mailto:carlaschmidt@utfpr.edu.br)

<sup>4</sup>Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio- PPGTCA  
Universidade Tecnológica Federal do Paraná – UTFPR – Medianeira/PR - Brasil  
[pattylla@gmail.com](mailto:pattylla@gmail.com)

#### Resumo

*Este trabalho tem por objetivo analisar a aplicação de algoritmos de mineração de dados para predição e classificação de variáveis produtivas que compõem as características das aves produzidas por uma cooperativa localizada na região oeste paranaense. 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. Três algoritmos de análise de dados, do software WEKA, foram utilizados na implementação dos modelos de predição e classificação. Para implementação dos modelos foram utilizados dados de 6000 lotes de aves das linhagens Coob e Coob Slow, obtidos do banco de dados da cooperativa, no período compreendido entre 01/07/2014 e 31/07/2016. Os resultados obtidos mostram que os modelos de predição fornecem estimativas confiáveis para as variáveis de resposta: Peso Médio e Índice de Eficiência Produtiva e o modelo de classificação apresenta um bom desempenho na classificação das linhagens das aves.*

**Palavras-chave:** mineração de dados; WEKA; produção de aves.

## Abstract

*This work aims to analyze the application of data mining algorithms for the prediction and classification of productive variables that make up the characteristics of the birds produced by a cooperative located in the western region of Paraná. The database provided by the company has a 2-year history of movement, containing the main production variables, from housing to the slaughtering stage. Three algorithms for data analysis, from the WEKA software, were used in the implementation of the prediction and classification models. For the implementation of the models, we used data from 6000 lots of birds of the Coob and Coob Slow lines, obtained from the cooperative's database, between 01/07/2014 and 07/31/2016. The results show that the prediction models provide reliable estimates for the response variables: Average Weight and Productive Efficiency Index and the classification model shows a good performance in the classification of the bird strains.*

**Key-words:** data mining; WEKA; birds production.

## 1. Introdução

A avicultura brasileira é considerada como uma das mais estruturadas do mundo, com números de produtividade significativos, graças a programas de qualidade como o de genética, nutrição, manejo, biosseguridade, boas práticas de produção, rastreabilidade, bem-estar animal e de preservação do meio ambiente (LUPATINI, 2015). A avicultura está presente em todas as regiões do país, gerando um efeito positivo na economia da maioria dos estados brasileiros (UBA, 2008).

Devido ao aumento do consumo de carne de frango em todo o mundo, nos últimos anos, os consumidores tornaram-se bem mais seletivos e exigentes, gerando assim uma maior competitividade entre as empresas alimentícias, levando-as a procurar vantagens competitivas. O domínio tecnológico é um dos fatores críticos para obter vantagens competitivas, fazendo com que a tecnologia e as informações, obtidas muitas vezes de banco de dados, sejam consideradas fatores importantes para as empresas do setor (PETERMANN; VARGAS, 2006)

A formatação de um modelo de inteligência, sobre uma base de dados de um sistema de produção de frangos de corte, permite a predição e a classificação de parâmetros produtivos importantes como: o peso médio das aves, o índice de eficiência produtiva e a linhagem das aves.

De fato, informações sobre variáveis produtivas são importantes fatores para tomada de decisão em uma empresa avícola. Segundo Moreira (2000), a tomada de decisão envolve uma situação problema onde se tem várias alternativas de solução. Este problema pode ser resolvido por meio da experiência do profissional responsável pela decisão ou através da utilização de técnicas matemáticas. Dentre estas técnicas pode-se citar a mineração de dados.

A mineração de dados é um processo de descoberta de informações em grandes conjuntos de dados (SHARMA, 2013). Tendo por objetivo a predição e a descrição. A predição faz uso de variáveis existentes no conjunto de dados para estimar valores desconhecidos. A descrição é voltada

para a busca de padrões descrevendo os dados e a subsequente apresentação para a interpretação do usuário (HAYKIN, 2005).

Neste contexto, este trabalho tem por objetivo analisar a aplicação de algoritmos de mineração de dados para predição e classificação de variáveis produtivas que compõem as características das aves produzidas por uma cooperativa localizada na região oeste paranaense.

## 2. Materiais e Métodos

Nesta seção aborda-se a metodologia utilizada para realizar essa pesquisa, detalhando os métodos propostos para realização dos experimentos, bem como as técnicas utilizadas.

A Empresa:

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 sua área de ação está centrada na região oeste paranaense, atuando em 12 municípios.

Variáveis Produtivas:

Realizou-se, neste trabalho, um levantamento histórico dos dados de dois anos de produção de frangos de corte (01/07/2014 a 31/07/2016) de 919 aviários, nas fases de alojamento e abate. A empresa, ao longo da criação dos frangos, faz o monitoramento dos seguintes indicadores: Ganho de Peso Diário (GPD), Consumo (CONS), Idade (ID), Conversão Alimentar (CA), Aves Alocadas (AL), Aves Abatidas (AB), Linhagem (LIN), Peso Médio (PM) e Índice de Eficiência Produtiva (IEP). A cooperativa mede a eficiência produtiva do avicultor por meio do Índice de Eficiência Produtiva (IEP). O IEP leva em conta a Conversão Alimentar (CA), o Ganho de Peso Diário (GPD) e a Viabilidade (VIAB) do lote. O IEP é obtido por meio da Equação 1 (SOBRINHO, 2010):

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

Além do IEP, o Peso Médio (PM) é outro índice monitorado pela cooperativa. Este índice é importante na adequação dos equipamentos automatizados de uma agroindústria de abate de frangos de corte. 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 (MARTINS, 2012).

O Peso Médio (PM) é a razão entre o peso vivo do lote e o número de frangos entregues (retirados) (Equação 2).

$$\text{Peso Médio (PM)} = \frac{\text{Peso total do lote (kg)}}{\text{Aves entregues (AB)}} \quad (2)$$

Algoritmos de Mineração de Dados:

Neste trabalho foram avaliados três algoritmos de mineração de dados:

*Multilayer Perception* (MLP): As redes MLP 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 MLP podem realizar tanto regressão quanto classificação (SANTOS et al., 2013; SEBASTIAN, 2016).

Naive Bayes: É um dos mais eficientes algoritmos de classificação. Apresenta desempenhos que chegam a atingir ou mesmo ultrapassar outros classificadores como redes neurais e árvores de decisão (AFROZ; RAHMAN, 2013). Este classificador é útil para tentar categorizar um conjunto de observações de acordo com uma variável de classe alvo, principalmente nos casos em que são usados um conjunto de treinamento pequeno e um pequeno número de preditores. Utilizando um conjunto de treinamento inicial, o Classificador Naive Bayes desenvolve um modelo para prever a probabilidade de que uma determinada observação pertence a cada classe da variável alvo (KARIM; RAHMAN, 2013).

*Linear Regression* (RL): Quando o resultado, ou classe, é numérica e todos os atributos são numéricos, a regressão linear é uma técnica a ser considerada. 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  $y = a_0 + a_1X_1 + \dots + a_nX_n$  tal que  $a_i \in \mathcal{R}$  e  $X_i$  é uma variável real (CANKURT et al., 2015; SING et al., 2017). Em mineração de dados o algoritmo de regressão linear é muito utilizado para fazer previsão, e pode ser encontrado em vários softwares estatísticos.

Métodos de Fragmentação:

Para criar os subconjuntos de dados, de treinamento e teste, foram usados 6000 lotes do banco de dados da cooperativa. Sendo 3000 da linhagem Coob e 3000 da linhagem Coob Slow. Neste trabalho utilizaram-se dois métodos de fragmentação: o método *Holdhout* 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) com 10 partições estratificadas. 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). Para validação dos modelos, implementados neste trabalho, utilizou-se um conjunto de 400 lotes de frangos que não participaram das fases de treinamento e teste. Os algoritmos foram treinados no software WEKA 3.8.1. Este software, desenvolvido pela Universidade de Waikato, provê vários algoritmos de mineração aplicáveis ao tratamento, treinamento e teste de um conjunto de dados (WITTEN; FRANK, 2005). O WEKA pode ser utilizado através de sua interface gráfica ou no modo console. É uma das ferramentas de mineração de dados mais utilizada no ambiente acadêmico.

Para o algoritmo MLP o número de neurônios da camada oculta ( $nn$ ) foi definido através da Equação 3:

$$nn = \frac{nCamadaEntrada+nCamadaSaída}{2} \quad (3)$$

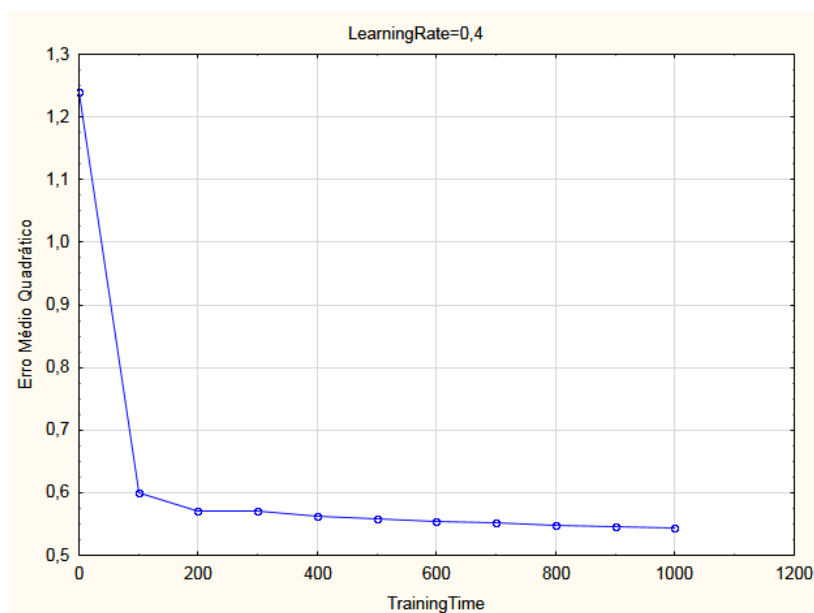
Para os outros parâmetros utilizou-se:  $LearningRate=0,3$ ,  $momentum=0,2$  e  $TrainingTime=1000$ . Observa-se que nesse caso foi utilizado a taxa de aprendizagem ( $LearningRate$ ) igual a 0,3 porque para esta taxa existe a convergência do erro (Figura 1), enquanto para uma taxa de 0,4, por exemplo, existe uma oscilação do erro (Figura 2). Todos os neurônios, das redes neurais implementadas neste trabalho, tem como função de ativação a sigmóide.

Figura 1 – Erro médio quadrático –  $LearningRate=0,3$



Fonte: Autoria própria

Figura 2 – Erro médio quadrático –  $LearningRate=0,4$



#### Avaliação dos Modelos:

Os modelos obtidos foram avaliados pelos parâmetros: coeficiente de correlação, erro médio absoluto, erro médio quadrático, erro absoluto relativo e raiz quadrada do erro médio quadrático. Para o modelo de classificação tem-se também: a quantidade de instâncias classificadas corretamente, quantidade de instâncias classificadas incorretamente, o índice Kappa e a matriz de confusão.

O índice Kappa ( $k$ ) (Equação 4) avalia o nível de concordância entre dois conjuntos de dados. Fornece uma idéia do quanto as observações afastam-se das esperadas, indicando o quão legítimas são as interpretações (CERQUEIRA, 2010).

$$k = \frac{P_0 - P_e}{1 - P_e} \quad (4)$$

Onde:  $P_0$ : é a taxa de aceitação relativa e  $P_e$ : a taxa hipotética de aceitação.

Os níveis de concordância são classificados conforme os critérios apresentados na Tabela 1.

Tabela 1 – Níveis de Concordância – Índice Kappa

Valor do Coeficiente Kappa	Nível de Concordância
<0	Não existe concordância
0 - 0,20	Concordância mínima
0,21 - 0,4	Concordância razoável
0,41 - 0,60	Concordância moderada
0,61 - 0,80	Concordância substancial
0,81 - 1	Concordância perfeita

Fonte: Cerqueira (2010).

### 3. Resultados e Discussão

#### MODELOS DE PREDIÇÃO:

Para encontrar os atributos relevantes para as variáveis de resposta utilizou-se o módulo de seleção de atributos do WEKA. Nesse ambiente foi utilizado o algoritmo *CorrelationAttributeEval* com o modo de busca *Ranker*. O modo *Ranker* faz uma avaliação individual dos atributos e os organiza com sua ordem de importância.

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). 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

<b>Filtro de classificação por correlação</b>			
<b>PM</b>		<b>IEP</b>	
Classificação	Atributos	Classificação	Atributos
0,89288	CONS	0,864	GPD
0,83283	GPD	0,3487	VIAB
0,64863	ID	0,2088	CONS
0,05182	LIN	0,0769	AB
0,00421	AB	0,0604	AL
0,00263	AL	0,028	LIN
-0,01521	CA	-0,118	ID
		-0,7246	CA

Fonte: Autoria própria


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

<b>Saída</b>	<b>Entradas</b>				
Peso Médio	CONS	GPD	ID	-	-
Índice de Eficiência Produtiva	GPD	VIAB	CONS	ID	CA

Algoritmo MLP: As redes modeladas foram especificadas como: MLP 5-3-1 (IEP) com 5 neurônios na camada de entrada, 3 neurônios na camada oculta e 1 na camada de saída (Figura 3) e MLP 3-4-1 (PM) com 3 neurônios na camada de entrada, 2 neurônios na camada oculta e 1 na camada de saída.

Figura 3 – Rede MLP 5-3-1 – Índice de Eficiência Produtiva



Fonte: Autoria própria

Algoritmo *Linear Regression* (LR): As equações de regressão obtidas, para as variáveis PM e IEP por meio do algoritmo *Linear Regression*, são apresentadas nas Equações 8 e 9.

$$PM = 0,0453GPD + 0,0046CONS + 0,0611ID + 2,7877 \quad (5)$$

$$IEP = 9,6214GPD - 79,7068CA - 49,9281CONS + 3,7623VIAB + 5,0565ID - 462,6132 \quad (6)$$

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

Tabela 4 – Resultados da aplicação dos algoritmos MLP e LR

	IEP		PM	
	LR	MLP	LR	MLP
Coefficiente de Correlação	0,9995	0,9994	0,9996	0,9995
Erro médio absoluto	0,5334	0,6531	0,0035	0,0034
Erro médio quadrático	0,7181	0,7918	0,0045	0,004
Erro absoluto relativo (%)	2,941	3,6006	2,8837	2,7622
Raiz quadrada do erro médio quadrático (%)	3,1635	3,488	2,994	2,8079

Fonte: Autoria própria

Verifica-se, por meio dos resultados apresentados na Tabela 4, que os dois algoritmos apresentam praticamente os mesmos resultados de coeficiente de correlação. A análise dos erros permite verificar que os melhores resultados foram obtidos usando o algoritmo de predição LR para

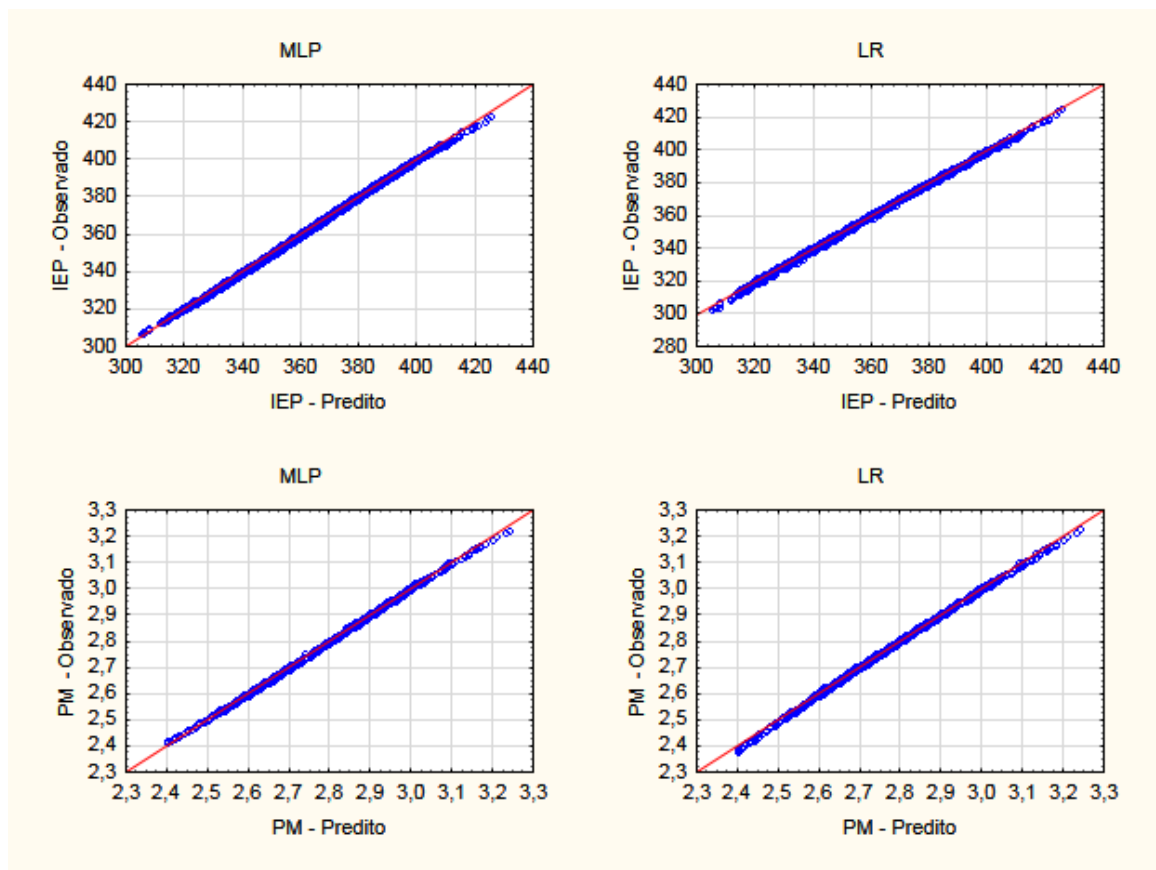


a variável Índice de Eficiência Produtiva (IEP) e o algoritmo MLP para a variável Peso Médio (PM).

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 4).

Figura 4 – Dados preditos em função de dados observados



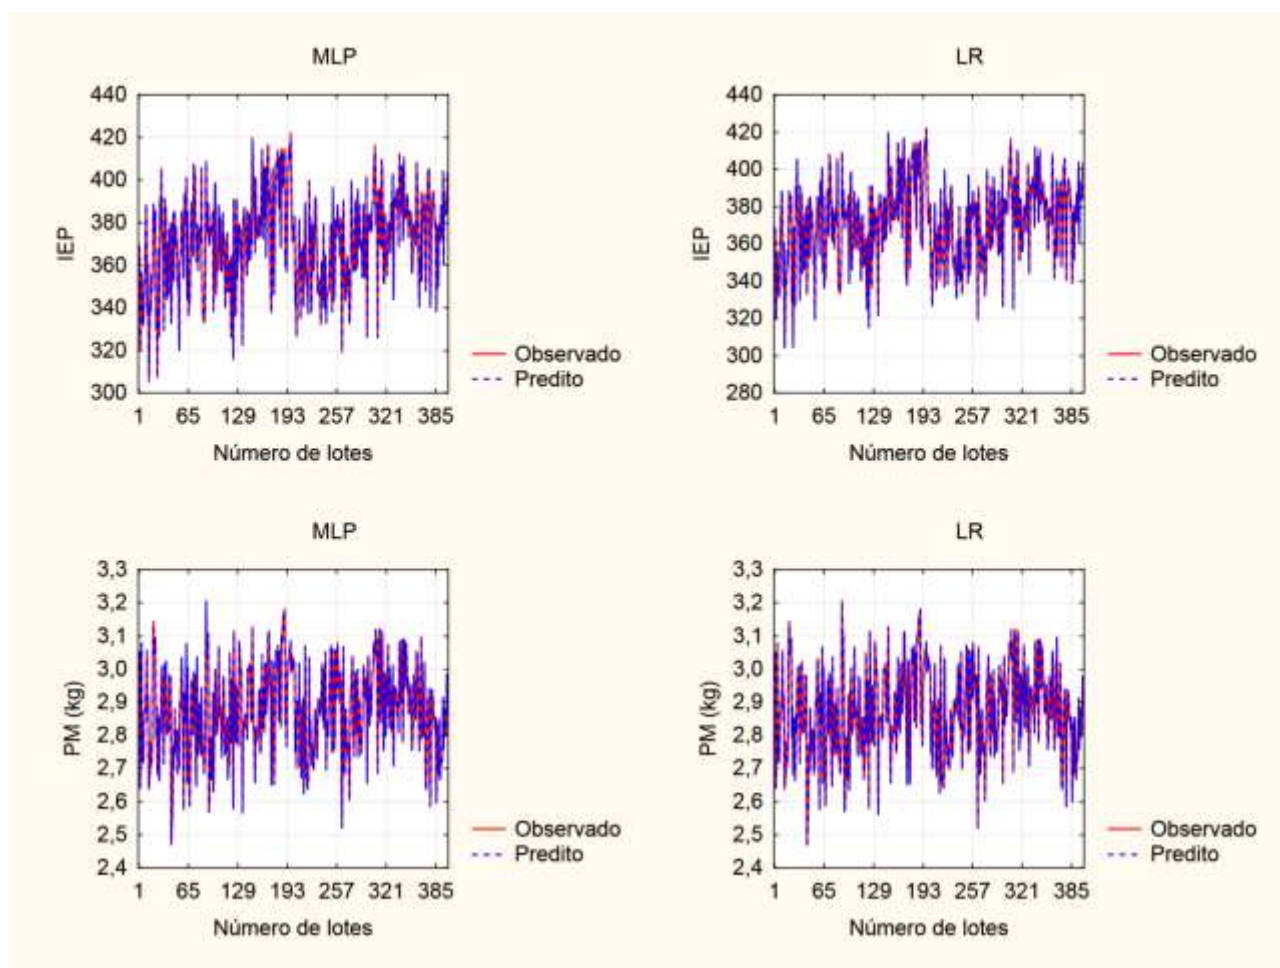
Fonte: Autoria própria

Observa-se, para os dois algoritmos, 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.

Validação dos Modelos:

Para validar os modelos compararam-se resultados obtidos dos algoritmos com resultados obtidos de 400 lotes de frango (Figura 5).

Figura 5 – Dados preditos em função de dados observados – 400 lotes



Fonte: Autoria própria

Pode-se observar, por meio dos gráficos apresentados na Figura 5, que existe uma boa aproximação entre os resultados reais e os preditos pelos dois algoritmos. É importante observar que o método de fragmentação *Cross-validation* foi mais preciso, apresentou erros menores (Tabela 5), que o método *Holdout* para a variável IEP.

Tabela 5– Resultados da aplicação do algoritmo MLP – *Cross-validation e Holdout*


	IEP	
	MLP - <i>Cross-validation</i>	MLP - <i>Holdout</i>
Coeficiente de Correlação	0,9996	0,9994
Erro médio absoluto	0,4558	0,6531
Erro médio quadrático	0,6132	0,7918
Erro absoluto relativo (%)	2,5187	3,6006
Raiz quadrada do erro médio quadrático (%)	2,7397	3,488

Fonte: Autoria própria

A vantagem de se usar o método *Cross-validation* é que neste método o treinamento é feito com todos os dados, e por isso pode gerar um resultado mais preciso.

Na Figura 6 apresentam-se os resultados obtidos com os 400 lotes utilizando o método *Cross-validation*.

Figura 6 – Dados preditos em função de dados observados – 400 lotes



Fonte: Autoria própria

Reali (2004), também obteve boas previsões, aplicando um modelo de redes neurais, para o Índice de Eficiência Produtiva (IEP) e para o Peso Médio (PM) de 1041 lotes, para os anos de 2001 e 2002, em uma Intervenção Agrícola do Rio Grande do Sul, utilizando o Software *NeuroShellPredictor*.

#### MODELO DE CLASSIFICAÇÃO:

Para encontrar os atributos relevantes, para variável de resposta Linhagem (LIN), utilizou-se o módulo de seleção de atributos do WEKA. Nesse ambiente foi utilizado o algoritmo *CfsSubsetEval* com o modo de busca *BestFirst*. Este algoritmo avalia o valor de um subconjunto de atributos considerando a habilidade preditiva individual de cada característica juntamente com o

grau de redundância entre eles. O modo *BestFirst* é o modo de pesquisa padrão do WEKA. Os atributos selecionados, para a classe LIN, foram a Conversão Alimentar (CA) e o Peso Médio (PM).

Ao rodar o classificador Naive Bayes, por meio do método *Cross-validation*, o programa oferece um relatório de desempenho (Tabela 6), onde gera o índice kappa, que no caso do treinamento/teste foi de 0,957. Ou seja, uma acurácia muito boa. Na matriz de confusão, a classe CB teve 127 amostras erroneamente classificada como CS e para classe CS 2 amostras como CB. Já para o conjunto de validação obteve-se um índice kappa de 0,985 e somente 3 amostra CB erroneamente classificada como CS.

Tabela 6 – Resultados da aplicação do algoritmo Naive Bayes

Sumário	Treinamento/Teste	Validação																		
Instâncias corretamente classificadas	5871 – 97,85%	397 - 99,25%																		
Instâncias incorretamente classificadas	129 – 2,15% %	3 - 0,75%																		
Estatística Kappa	0,957	0,985																		
Erro médio absoluto	0,0495	0,025																		
Erro médio quadrático	0,1448	0,0958																		
Erro absoluto relativo (%)	9,8927	5,0062																		
Raiz quadrada do erro médio quadrático (%)	28,9604	19,1662																		
Total de Instâncias	6000	400																		
Matriz de confusão	<table border="0"> <tr> <td><i>a</i></td> <td><i>b</i></td> <td></td> </tr> <tr> <td>2873</td> <td>127</td> <td><i>a = CB</i></td> </tr> <tr> <td>2</td> <td>2998</td> <td><i>b = CS</i></td> </tr> </table>	<i>a</i>	<i>b</i>		2873	127	<i>a = CB</i>	2	2998	<i>b = CS</i>	<table border="0"> <tr> <td><i>a</i></td> <td><i>b</i></td> <td></td> </tr> <tr> <td>197</td> <td>3</td> <td><i>a = CB</i></td> </tr> <tr> <td>0</td> <td>200</td> <td><i>b = CS</i></td> </tr> </table>	<i>a</i>	<i>b</i>		197	3	<i>a = CB</i>	0	200	<i>b = CS</i>
<i>a</i>	<i>b</i>																			
2873	127	<i>a = CB</i>																		
2	2998	<i>b = CS</i>																		
<i>a</i>	<i>b</i>																			
197	3	<i>a = CB</i>																		
0	200	<i>b = CS</i>																		

#### 4. Conclusões

Este trabalho teve por objetivo analisar a aplicação algoritmos de mineração de dados na predição e classificação de variáveis produtivas que compõem as características das aves a serem abatidas em uma cooperativa localizada na região oeste paranaense.

A empresa forneceu um banco de dados com um histórico de movimentação de 2 anos, contendo dados desde o alojamento até a fase de abate. Com as variáveis produtivas, obtidas deste banco de dados, construíram-se modelos de predição baseados em dois algoritmos de análise de dados: Redes Neurais Artificiais (MLP) e Regressão Linear (LR). Os modelos obtidos, por meio dos algoritmos, estão bem ajustados como pode ser observado pela correlação entre os dados preditos e observados apresentados na Figura 4.

Pode-se observar, da Tabela 2, que o consumo e o ganho de peso diário foram os parâmetros produtivos que mais contribuíram para as variáveis de resposta (Peso Médio e Índice de Eficiência Produtiva). Observou-se, também, que a Linhagem das aves não teve praticamente influência sobre às variáveis de resposta.

Quando os modelos, implementados para prever as variáveis Peso Médio e Índice de Eficiência Produtiva, foram aplicados a 400 lotes de frangos, as previsões foram bem precisas e as diferenças entre valores reais e preditos foram pequenas (Figura 5). Portanto, a proximidade entre valores preditos e reais demonstram a boa capacidade de generalização dos modelos implementados neste trabalho.

Observou-se, também, que o algoritmo de Naive Bayes apresentou um bom desempenho na classificação das linhagens das aves. Para o conjunto de validação apresentou 99,25% de instâncias corretamente classificadas.

## Referências

- AFROZ, F.; RAHMAN, R. M. Comparison of various classification techniques using different data mining tools for diabetes diagnosis. . **Journal of Software Engineering and Applications**, vol. 6, 85-97, 2013.
- CANKURT, S.; SUBASI, A. Comparison of linear regression and neural network models forecasting tourist arrivals to turkey. **Eurasian Journal of Science & Engineering**. 2015.
- CERQUEIRA, P. H. R. Um estudo sobre o reconhecimento de padrões: um aprendizado supervisionado com classificador bayesiano. Dissertação de mestrado. Universidade de São Paulo. Piracicaba: 2010.
- HAYKIN, S. **Neural networks: a comprehensive foundation**. New Delhi: Pearson Prentice Hall, 2005.
- KARIM, M.; RAHMAN, R. M. Decision tree and Naive Bayes algorithm for classification and generation of actionable knowledge for direct marketing. **Journal of Software Engineering and Applications**, vol. 6, 196-206, 2013.
- LUPATINI, F. Avaliação do efeito de variáveis produtivas na conversão alimentar de frangos de corte. Universidade Federal de Goiás, Goiânia, 2015.
- MARTINS, J. M. S.; TAVEIRA, R. Z.; HITZ, F. H.; SANTOS, M. P. Desempenho zootécnico de linhagens de frango de corte de crescimento rápido. **PUBVET**, vol. 6, 2012.
- MOREIRA, D. A. **Administração da produção e operações**. São Paulo: Pioneira, 2000.

PETERMANN, R. J.; VARGAS, F. L. Modelo de mineração de dados para classificação de clientes em telecomunicação. Dissertação de mestrado. Pontifícia Universidade Católica do Rio Grande do Sul. Porto Alegre: 2006.

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

SANTOS, R. B.; RUPP, M., BONZI, S. J.; FILETI, A. M. F. Comparision between multilayer feedforward neural networks and a radial basis function network to detect and locate leaks in pipelines transporting gás. **Chemical Engineering Transactions**. Vol. 32, 2013.

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

SHARMA, N. B. G.; BHARGAVA, R. MATHURIA, M. Decision tree analysis on j48 algoritm for data mining. **International Journal of Advanced Research in Computer Science and Software Engineering**, vol. 6, 2013.

SING, G. P.; KUMAR, R.; SHARMA, A. QSAR Studies of breast carcinoma using artificial neural network, bayesian classifier and multiple linear regression. **International Research Journal of Engineering and Technology**, vol. 4, 2017.

SOBRINHO, R. F. Competitividade na cadeia de valor da avicultura de corte. Dissertação de mestrado.UNIOESTE. Toledo: 2010.

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

WITTEN I. H.; FRANK E. **Data mining: practical machine learning tools and techniques**. San Francisco: Morgan Kaufmann, 2005.

Recebido: 20/03/2017

Aprovado: 16/09/2018