

## MINERAÇÃO DE DADOS EM PARÂMETROS DE QUALIDADE DO LEITE

**RUAN BERNARDY<sup>1</sup>, GIZELE INGRID GADOTTI<sup>2</sup>, ADRIEL NADAL<sup>3</sup>, GRACIELA BUCK<sup>4</sup>, RITA DE CASSIA MOTA MONTEIRO<sup>5</sup>, ROGÉRIO FÔLHA BERMUDES<sup>6</sup>**

<sup>1</sup>Eng. Agrícola e Mestrando em Ciências Ambientais - Universidade Federal de Pelotas - ruanbernardy@yahoo.com.br.

<sup>2</sup>Eng. Agrícola e Profª. Dra. em Ciência e Tec. de Sementes - Universidade Federal de Pelotas - gizele.gadotti@ufpel.edu.br.

<sup>3</sup>Graduando em Engenharia Agrícola - Universidade Federal de Pelotas - adriel.nadal@gmail.com.

<sup>4</sup>Graduanda em Engenharia Agrícola - Universidade Federal de Pelotas - graciela-buck@hotmail.com.

<sup>5</sup>Eng. Agrícola e Ma. em Ciência e Tecnologia de Sementes - Universidade Federal de Pelotas - ritamonteiro@gmail.com.

<sup>6</sup>Médico Veterinário e Dr. em Zootecnia - Universidade Federal de Pelotas - rogerio.bermudes@ufpel.edu.br.

Apresentado

no LI Congresso Brasileiro de Engenharia Agrícola - CONBEA 2022  
27 a 29 de outubro de 2022 - Pelotas - RS, Brasil

**RESUMO:** A pecuária leiteira brasileira possui um papel importante no país, tanto para o contexto social quanto econômico. Além disso, o produtor é remunerado pela indústria com base nos padrões exigidos pela legislação, assim, o monitoramento da qualidade do leite feito pelos laticínios se torna fundamental para conseguir um bom valor agregado no leite. O objetivo do trabalho foi avaliar os parâmetros de qualidade do leite com uso de técnicas de aprendizado de máquina, de modo a buscar padrões e correlações entre as estações climáticas do ano. Foram coletadas amostras de leite de 23 propriedades na região do município de Pelotas - RS, analisando Proteína Bruta, Contagem de Células Somáticas, Nitrogênio Ureico e Caseína, em todos os meses de 2021. Os classificadores utilizados foram Random Forest e Multilayer Perceptron (MLP). Os dados foram submetidos ao filtro Resample, para enviesar os mesmos. Foi utilizado o *software* Weka para executar os algoritmos. O Random Forest obteve 84,72% de assertividade, enquanto o MLP chegou a um percentual de 86,11%. Na árvore de decisão, a proteína bruta, seguida pela caseína e nitrogênio uréico, foram utilizados pelos classificadores nessa ordem de importância. Através dos resultados da técnica de aprendizado de máquinas, verificou-se que é possível diferenciar o leite produzido nas diferentes estações do ano utilizando inteligência artificial.

**PALAVRAS-CHAVE:** Pecuária leiteira. Aprendizado de máquina. Estação climática.

## DATA MINING IN MILK QUALITY PARAMETERS

**ABSTRACT:** Brazilian dairy farming plays an important role in the country, both social and economic. In addition, the producer is paid by the industry based on the standards required by legislation, so the monitoring of the quality of the milk made by the dairies becomes essential to achieve a good added value in milk. The objective of this work was to evaluate milk quality parameters using machine learning techniques to look for patterns and correlations between the climatic seasons of the year. Milk samples were collected from 23 properties in the region of Pelotas - RS, analyzing crude protein, somatic cell count, urea nitrogen, and casein in all months of 2021. The classifiers used were Random Forest and Multilayer Perceptron (MLP). The data were submitted to the Resample filter to bias them. Weka software was used to run the algorithms. Random Forest obtained 84.72% of assertiveness, while MLP reached a percentage of 86.11%. In the decision tree, crude protein, followed by casein and urea nitrogen, was used

by the classifiers in this order of importance. Through the machine learning technique results, it was found that it is possible to differentiate the milk produced in different seasons using artificial intelligence.

**KEYWORDS:** Dairy farming. Machine learning. Weather station.

**INTRODUÇÃO:** A região sul do Brasil é a maior produtora de leite do país (SEAB, 2019). A faixa formada pelo oeste catarinense, noroeste gaúcho e sudoeste paranaense é onde a produtividade cresce anualmente, devido ao clima favorável para manejo dos animais e cultivo de pastagem, além da mão-de-obra qualificada (SEAB, 2019). A pastagem é o componente principal na produção de leite nessas regiões, pois permite aos agricultores um alto rendimento (BREITENBACH, 2018). No entanto, nos últimos anos vem sendo adotado os sistemas de confinamento, onde estes utilizam compostagem como alimento, além de elevar a qualidade do produto, quando comparado com o sistema anterior (WINSTEN et al., 2000). Alguns pesquisadores estão analisando o uso de algoritmos que trabalham com redes neurais na indústria alimentícia, como por exemplo para identificar parâmetros de qualidade do leite (VIEIRA et al., 2019; ZHU et al., 2021) e previsão de produtividade (SOARES et al., 2015). Suseendran e Duraisamy (2021) propuseram um modelo baseado em aprendizado de máquina para predição da produtividade de leite com base no estado de saúde das vacas e ingestão de ração. Em outro trabalho realizado por Ji et al. (2022), os autores demonstraram um quadro que forma automaticamente modelos utilizando dados para prever a composição do leite (teor de gordura e proteínas), além de outros parâmetros considerados importantes para o produtor. Segundo Wang et al. (2022), o aprendizado de máquina pode trazer continuamente novos avanços no setor leiteiro, melhorando eficiência de produção, além da saúde e bem-estar dos animais, acrescentando também novos conhecimentos que auxiliam no aumento de qualidade do leite e produção. De acordo com relatório mensal divulgado em março de 2022 pela Companhia Nacional de Abastecimento — CONAB, a produção de leite no Brasil caiu 2,2% em 2021 (CONAB, 2022). O valor pago ao produtor também sofreu redução, ficando 2,6% menor nas principais regiões produtoras, impulsionado pela alta nos custos de produção (CONAB, 2022). Lordão et al., (2013) comentam que a bovinocultura de leite no Brasil é caracterizada por pequenas propriedades que trabalham com agricultura familiar, carecendo de assistência técnica e informações, refletindo diretamente em um leite com baixa qualidade. Com isso, ferramentas que auxiliem na rápida interpretação dos dados favorecem estes produtores a conseguirem produzir leite de qualidade e de forma sustentável (BOLSONELLO et al., 2019). Além disso, o produtor é remunerado pela indústria com base nos padrões exigidos pela legislação, assim, o monitoramento da qualidade do leite feito pelos laticínios se torna fundamental para conseguir um bom valor agregado no leite (VILELA et al., 2016). Sendo assim, é necessário desenvolver métodos rápidos de avaliação, com boa precisão e baixo custo, de modo a acompanhar a agricultura moderna e permitir ao produtor entregar um produto de qualidade (BUNACIU et al., 2016). Deste modo, o objetivo do trabalho foi avaliar os parâmetros de qualidade do leite com uso de técnicas de aprendizado de máquina, de modo a buscar padrões e correlações entre as estações climáticas do ano.

**MATERIAL E MÉTODOS:** Realizou a coleta de amostras em 27 propriedades na região do município de Pelotas – Rio Grande do Sul, analisando Proteína Bruta, Contagem de Células Somáticas, Nitrogênio Ureico e Caseína, em todos os meses de 2021, de modo a obter as características do leite em todas as estações climáticas. Após o pré-processamento dos dados, foi identificado que algumas propriedades não possuíam valores em alguns meses, sendo necessário excluir de modo que não tivessem dados faltantes, totalizando ao final dessa etapa 23 propriedades, gerando 18 linhas de dados com 6 atributos. Como os dados são considerados

supervisionados, estes foram submetidos a classificação de acordo com a estação em que as análises foram realizadas, supervisionando o conjunto de dados nas quatro estações do ano, conforme Tabela 1.

TABELA 1 - Discriminação dos dados entre os atributos analisados para mineração de dados para análise de parâmetros do leite.

Atributo	Descrição	Valor
Propriedade	Propriedade	{1-18}
Proteína Bruta	PB	{g/100g}
Contagem de Células Somáticas	CCS	{CS/mL}
Nitrogênio Ureico	NUL	{mg/dL}
Caseína	Caseína	{g/100g}
Classificação dos Dados	Decisão Tomada	{verão, outono, inverno e primavera}

Durante a etapa de pré-análise das informações geradas, além das linhas com valores faltantes, dados considerados equivocados também foram excluídos, de modo a preparar o conjunto de dados para que a ferramenta pudesse efetuar a correta leitura e análise de aprendizagem. Os valores foram recebidos em formato .xls (Excel), sendo necessário colocar todos os atributos em uma única linha e, cada valor, em colunas, abaixo do seu respectivo atributo. Posteriormente foi convertido o arquivo para formato .csv, com isso o conjunto de dados foi executado com auxílio do software Bloco de Notas do Microsoft Windows 11, necessitando a substituição das “vírgulas”, quando o valor atribuído fosse decimal (número com vírgulas), para “pontos” e dos “pontos e vírgula”, que realizam a divisão das colunas dos atributos, para “vírgulas”. Para a tarefa de mineração de dados, foi utilizado o *software* Weka, versão 3.8.5, desenvolvido pela *University of Waikato* (EIBE et al., 2020). Os classificadores utilizados foram Random Forest, que trabalha com árvores de decisão, e Multilayer Perceptron (MLP), que utiliza redes neurais. Com intuito de resolver esse problema de dados desbalanceados e não tendenciar o algoritmo, utilizou-se o Resample, um filtro de instância não supervisionada que mantém a distribuição de classe na subamostra, onde, alternativamente, pode ser configurado para enviesar a distribuição de classes à uma distribuição uniforme (GADOTTI et al., 2022). Foi utilizado para treinamento e teste a validação cruzada desses dados, subdividindo-os em 10 subconjuntos (10 folds). Dessas 10 subamostras, uma foi retida para validação do modelo e as restantes foram utilizadas para treinamento. Como eram 10 folds, ou dobras, esse processo foi repetido 10 vezes, sempre retendo um conjunto diferente para validação. Essa técnica reduz a probabilidade de que coincidências subavaliem ou sobreavaliem o desempenho para uma determinada configuração. Todos os resultados reportados neste trabalho utilizaram essa técnica. Para verificar a precisão dos algoritmos foram utilizadas as seguintes métricas de avaliação: Acurácia, Precisão, Recall, F-measure e Área ROC, de acordo com Lever et al. (2016). Por meio da matriz de confusão, foram extraídos os valores de verdadeiros positivos (TP), falsos positivos (FP), verdadeiros negativos (TN) e falsos negativos (FN), com a finalidade de calcular as métricas Recall e Precisão, através de equações propostas por Medeiros et al. (2020). A Figura 1 sintetiza todas as etapas realizadas neste trabalho.

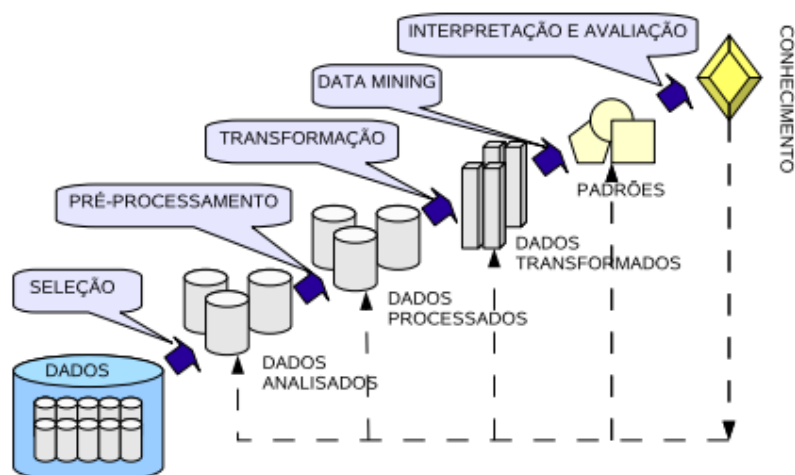


FIGURA 1 - Sequência de operação utilizando mineração de dados.  
 Fonte: VASCONCELOS; CARVALHO, 2018.

**RESULTADOS E DISCUSSÃO:** A análise dos parâmetros de qualidade do leite é importante para a precificação do produto ao agricultor, pois é através dos valores máximos e mínimos exigidos pela norma que a empresa sabe quanto irá pagar por litro de leite. Por isso, quando o produtor conhece o que afeta o percentual de gordura e proteína, este consegue trabalhar para entregar o leite com os padrões exigidos, conseguindo elevar os lucros da propriedade. O aprendizado de máquina é considerado como subcampo da ciência da computação, onde está trabalhando com reconhecimento de padrões, utilizando técnicas de mineração de dados para extração de conhecimento (HAN; KAMBER; PEI, 2012; BOLSONELLO et al., 2019). O objetivo principal é fazer com que o computador aprenda a partir de suas próprias experiências (MITCHELL, 1997). A partir do trabalho realizado, o algoritmo Random Forest obteve 84,72% de assertividade, enquanto o MLP chegou a um percentual de 86,11%, mostrando que o aprendizado de máquina conseguiu encontrar um padrão na ocorrência dos dados em cada estação do ano. Em estudo realizado por Ma et al. (2018), a rede neural desempenhou bons resultados ao prever a temperatura de armazenagem de leite cru e suas variações. Djekic et al. (2018), utilizando lógica *fuzzy*, também conseguiram validar o uso do aprendizado de máquina em avaliação de características do leite.

TABELA 2 - Acurácias dos algoritmos utilizados.

Classificadores	Acurácia				
	Recall	Precisão	ROC Area	F-Measure	Classe
Random Forest	0,944	0,773	0,981	0,850	Verão
	0,833	0,833	0,984	0,833	Outono
	0,833	0,833	0,951	0,833	Inverno
	0,778	1,000	0,951	0,875	Primavera
MLP	0,889	0,941	0,990	0,914	Verão
	0,889	0,941	0,993	0,914	Outono
	0,889	0,727	0,889	0,800	Inverno
	0,778	0,875	0,907	0,824	Primavera

A combinação das técnicas de calorimetria de varredura diferencial (DSC) e aprendizado de máquinas possibilitaram a Farah et al. (2021) em seu estudo detectar a adição de adulterantes no leite cru através dos classificadores Random Forest (RF), Gradiente boosting machine (GBM) e Multilayer Perceptron (MPL), surgindo assim uma nova possibilidade de monitoramento da qualidade em indústrias de laticínios. Neste caso a temperatura foi um fator de grande contribuição para prever os modelos de classificação, a temperatura de pico de cristalização auxiliou nos modelos de GBM e RF, já no caso do MPL foram as temperaturas de pico de ebulição, inicial de cristalização e inicial de ebulição. Para a Tabela 3, a matriz de confusão obtida nos testes com o Random Forest mostra uma classificação incorreta de alguns dados para estações que ocorrem logo após ou é antecedida. Isso se deve a ocorrência de condições climáticas similares de meses que são vizinhos, pois o manejo dos animais se mantém igual.

TABELA 3 - Matriz de confusão do algoritmo Random Forest com dados de leite.

		Predição			
		Verão	Outono	Inverno	Primavera
Classe Real	Verão	17	0	1	0
	Outono	2	15	1	0
	Inverno	2	1	15	0
	Primavera	1	2	1	14

A Tabela 4 descreve a matriz de confusão para o MLP, onde a classe de maior erro é a de primavera, onde há dados classificados como inverno. Novamente pode ser explicado pela ocorrência desta estação logo após a anterior.

TABELA 4 - Matriz de confusão do algoritmo MLP com dados de leite durante o ano.

		Predição			
		Verão	Outono	Inverno	Primavera
Classe Real	Verão	16	0	1	1
	Outono	0	16	1	1
	Inverno	1	1	16	0
	Primavera	0	0	4	14

Na Figura 2 é apresentada a árvore de decisão do algoritmo J48, que também trabalha com árvore de decisão. De acordo com Moraes (2020), a escolha da árvore de decisão pelo algoritmo J48 ocorre por essa ser uma derivação em Java do algoritmo C4.5, um dos mais utilizados e confiáveis classificadores estatísticos. Ele constrói a árvore de decisão utilizando o conceito de Entropia. Pela entropia, o algoritmo escolhe o atributo que mais particiona os dados por meio do ganho de informação normalizado (MORAES, 2020). Aqui é possível analisar que o PB e Caseína são os dois parâmetros que pesaram na classificação. Mesmo o NUL estando diretamente relacionado com a alimentação, esse obteve peso menor em relação aos outros valores para diferenciar as estações do ano.

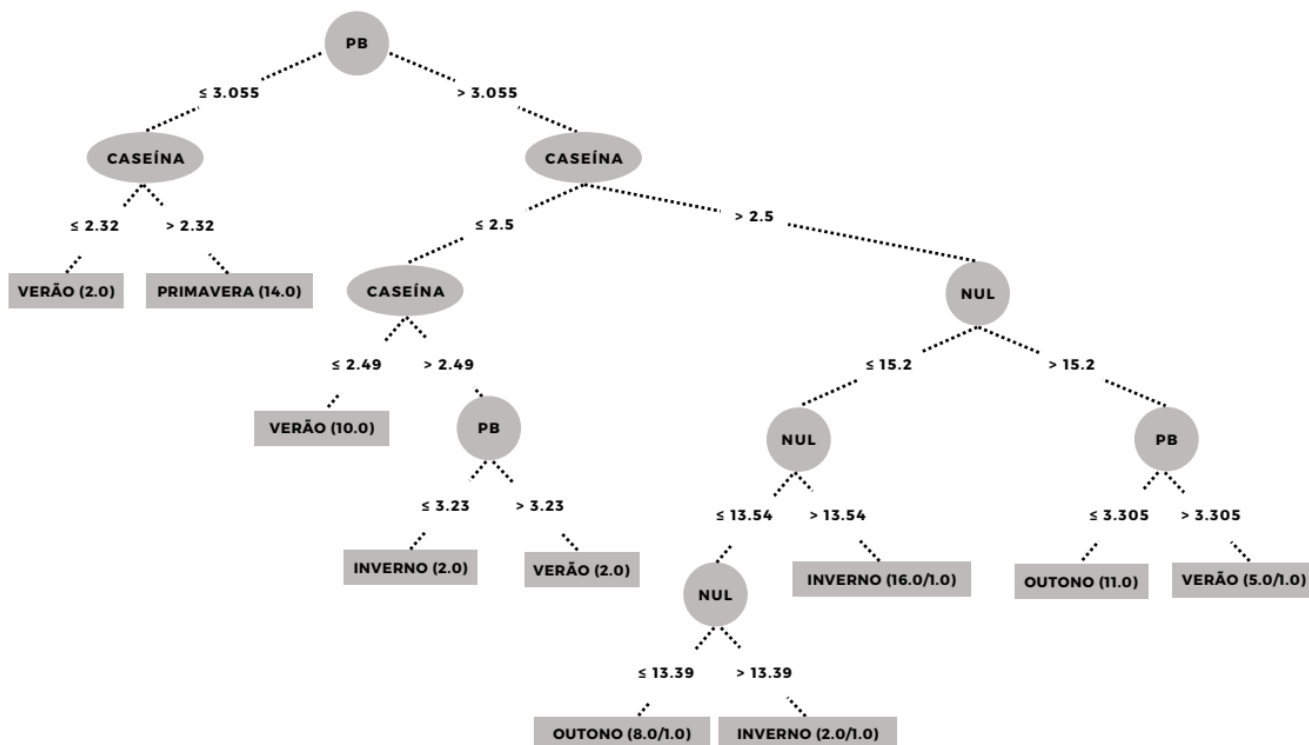


FIGURA 2 - Árvore de Decisão resultante do algoritmo J48 com dados de leite.

Foi também realizado correlação de Pearson entre os dados. Essa matriz de correlação é utilizada para analisar estatisticamente variáveis que se relacionam entre si. De acordo com Lidiane et al., (2018), o grau de relação é dado pelo coeficiente de Pearson, também nomeado como coeficiente de correlação. Esse coeficiente é dado por um número entre -1 e 1, que expressa o grau de dependência linear entre dois dados quantitativos. Quando o resultado é um número negativo, indica que enquanto uma variável aumenta, o outro valor diminui, ou seja, são proporcionalmente inversos, da mesma forma que se o valor for positivo, ambas as variáveis analisadas são proporcionais, aumentando ou diminuindo juntas (JOHNSON; WICHERN, 2007). A Figura 3 ilustra o que foi descrito acima.




FIGURA 3 – Coeficiente de Correlação de Pearson.

Fonte: OLIVEIRA, 2021.

Neste trabalho, os cálculos foram executados utilizando a plataforma Google Colaboratory, conhecido como “Google Colab”, disponível gratuitamente pela empresa Google. Após a análise, o principal resultado encontrado foi entre PB e Caseína, com valor de 0,95 positivo, ou 95%, mostrando a forte relação entre essas duas variáveis. Isso é devido a Caseína ser considerada também uma proteína, estando inserida na primeira.

**CONCLUSÕES:** Através dos resultados da técnica de aprendizado de máquinas, verificou-se que é possível diferenciar o leite produzido nas diferentes estações do ano utilizando inteligência artificial. Essa ferramenta poderá auxiliar indústrias do setor nas análises de qualidade do leite, além de ajudar os produtores a encontrar problemas e possíveis soluções para produzir este alimento nos padrões exigidos pela legislação.

**AGRADECIMENTOS:** Agradecemos a Fundação Assistencial e Previdenciária da Extensão Rural no Rio Grande do Sul (FAPERGS) e também a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela disponibilidade financeira no fornecimento de bolsas de pesquisa para realização deste trabalho.

## **REFERÊNCIAS:**

BOLSONELLO, Julia Elisabett Klocoski; FREDDO, Ademir Roberto; GALLINA, André Lazarin; ELIAS, Fabiana; STARIKOFF, Karina Ramirez. APLICAÇÃO DO APRENDIZADO DE MÁQUINA SOBRE A QUALIDADE DA PRODUÇÃO AGROECOLÓGICA DE LEITE. In: JORNADA DE INICIAÇÃO CIENTÍFICA E TECNOLÓGICA, 9., 2019, Cerro Largo. **Anais [...]**. Cerro Largo: Universidade Federal da Fronteira Sul, 2019. v. 9, p. 1-4. Disponível em: <<https://portaleventos.uffrs.edu.br/index.php/JORNADA/article/view/11533>>. Acesso em: 26 ago. 2022.

BREITENBACH, Raquel. Economic Viability of Semi-Confined and Confined Milk Production Systems in Free-Stall and Compost Barn. **Food and Nutrition Sciences**, [S.L.], v. 09, n. 05, p. 609-618, jan. 2018. Scientific Research Publishing, Inc. DOI: <<http://dx.doi.org/10.4236/fns.2018.95046>>.

BUNACIU, Andrei; ABOUL-ENEIN, Hassan Y.; HOANG, Vu Dang. Vibrational spectroscopy used in milk products analysis: A review. **Food Chemistry**, v. 196, p. 877-884, 2016.

CONAB. Companhia Nacional de Abastecimento. **Relatório Mensal, Março de 2022**. Quarto Levantamento, 2022. CONAB, Brasília. Disponível em: <<https://www.conab.gov.br/info-agro/analises-do-mercado-agropecuário-e-extrativista/analises-do-mercado/historico-mensal-de-leite>>. Acesso em: 17 maio 2022.

DJEKIC, Ilija; SMIGIC, Nada; GLAVAN, Ruzica; MIOCINOVIC, Jelena; TOMASEVIC, Igor. Transportation sustainability index in dairy industry: fuzzy logic approach. **Journal Of Cleaner Production**, v. 180, p. 107-115, abr. 2018. Elsevier BV. DOI: <http://dx.doi.org/10.1016/j.jclepro.2018.01.185>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0959652618302075>>. Acesso em: 19 maio 2022.

EIBE, F.; MARK, A. H.; IAN, H. W. **The WEKA Workbench**. Online Appendix for Data Mining: Practical Machine Learning Tools and Techniques, Morgan Kaufmann, Fourth Edition, 2020.

GADOTTI, G. I. et al. Aprendizado de máquina para classificação de lotes de sementes de soja. **Engenharia Agrícola**, Jaboticabal, v. 42, special issue, 2022. DOI: <http://dx.doi.org/10.1590/1809-4430-Eng.Agric.v42nepe20210101/2022>. Disponível em: <<https://www.scielo.br/j/eagri/a/LtTLRpzgNQPWp5mw3qRMdtM/?format=pdf&lang=en>>. Acesso em: 21 mar. 2022.

HAN, J.; KAMBER, M.; PEIJ. **Data mining concepts and techniques**. USA: Elsevier, 2012.

JI, Boyu; BANHAZI, Thomas; PHILLIPS, Clive J.C.; WANG, Chaoyuan; LI, Baoming. A machine learning framework to predict the next month's daily milk yield, milk composition and milking frequency for cows in a robotic dairy farm. **Biosystems Engineering**, [S.L.], v. 216, p. 186-197, abr. 2022. Elsevier BV. DOI: <<http://dx.doi.org/10.1016/j.biosystemseng.2022.02.013>>.

JOHNSON, R. A.; WICHERN, D. W. **Applied multivariate statistical analysis**, 6 ed. Madison: Prentice Hall International, 2007. 816p.

LEVER, Jake; KRZYWINSKI, Martin; ALTMAN, Naomi. Classification evaluation. **Nature Methods**, v. 13, n. 8, p. 603-604, set. 2016. Disponível em: <<https://www.nature.com/articles/nmeth.3945.pdf>>. Acesso em: 07 março 2022.

LIDIANE, Lordelo Mendes Kruschewsky; KUANG, Hongyu; PATRÍCIA, Borja Campos; MILTON, Porsani José. Análise Fatorial por Meio da Matriz de Correlação de Pearson e Policórica no Campo das Cisternas. **E&S Engineering and Science**, [S.L.], v. 7, n. 1, p. 58-70, 1 abr. 2018. Universidade Federal de Mato Grosso. DOI: <<http://dx.doi.org/10.18607/es201875266>>.

LORDÃO, A. C. et al. Implantação de medidas de higiene na ordenha para melhoria da qualidade do leite no município de Paty do Alferes/RJ, Brasil. **Archives of Veterinary Science**, v. 18, n. 4, 2013.

MA, Weihong; FAN, Jinwei; LI, Qifeng; TANG, Yuhang. A raw milk service platform using BP Neural Network and Fuzzy Inference. **Information Processing in Agriculture**, v. 5, n. 3, p. 308-319, set. 2018. Elsevier BV. DOI: <http://dx.doi.org/10.1016/j.inpa.2018.04.001>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2214317318300167>>. Acesso em: 19 maio 2022.

MEDEIROS, A. D. et al. Interactive machine learning for soybean seed and seedling quality classification. **Scientific Reports**, [S.L.], v. 10, n. 1, p. 1-10, 2020. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/s41598-020-68273-y>. Disponível em: <<https://www.nature.com/articles/s41598-020-68273-y.pdf>>. Acesso em: 07 mar. 2022.

MITCHELL TM. **Machine Learning**: McGraw–Hill Science/Engineering/Math; 1997.

MORE: Mecanismo online para referências, versão 2.0. Florianópolis: UFSC Rexlab, 2013. Disponível em: <<http://www.more.ufsc.br/>>. Acesso em: 04 julho 2022.

OLIVEIRA, Bruno. **COEFICIENTES DE CORRELAÇÃO**. 2019. Disponível em: <<https://operdata.com.br/blog/coeficientes-de-correlacao/>>. Acesso em: 06 maio 2022.

SECRETARIA DO ESTADO E DO ABASTECIMENTO - SEAB. 2019. **Bovinocultura de Leite/Aspectos do Brasil e Paraná**. SEAB, Curitiba, PR, Brasil. Disponível em: <[http://www.agricultura.pr.gov.br/sites/default/arquivos\\_restritos/files/documento/2019-09/leite\\_2019\\_v1.pdf](http://www.agricultura.pr.gov.br/sites/default/arquivos_restritos/files/documento/2019-09/leite_2019_v1.pdf)>. Acesso em: 25 ago. 2022.

SOARES, Fátima Cibele; ROBAINA, Adroaldo Dias; PEITER, Marcia Xavier; RUSSI, Jumar Luis. Predição da produtividade da cultura do milho utilizando rede neural artificial. **Ciência Rural**, [S.L.], v. 45, n. 11, p. 1987-1993, nov. 2015. FapUNIFESP (SciELO). DOI: <<http://dx.doi.org/10.1590/0103-8478cr20141524>>.

SUSEENDRAN, G.; DURAISAMY, Balaganesh. Predication of Dairy Milk Production Using Machine Learning Techniques. **Intelligent Computing and Innovation on Data Science**, [S.L.], p. 579-588, jan. 2021. Springer Singapore. DOI: <[http://dx.doi.org/10.1007/978-981-16-3153-5\\_60](http://dx.doi.org/10.1007/978-981-16-3153-5_60)>.

VASCONCELOS, Livia Maria Rocha de; CARVALHO, Cedric Luiz de. Aplicação de Regras de Associação para Mineração de Dados na Web. **Revista Telfract**, [S.L.], v. 1, n. 1, p. 1-20, jan. 2018. Disponível em: <<https://telematicafractional.com.br/revista/index.php/telfract/article/view/8>>. Acesso em: 26 ago. 2022.

VIEIRA, Gustavo N. A.; OLAZAR, Martín; FREIRE, José T.; FREIRE, Fábio B. Real-time monitoring of milk powder moisture content during drying in a spouted bed dryer using a hybrid neural soft sensor. **Drying Technology**, [S.L.], v. 37, n. 9, p. 1184-1190, 1 out. 2018. Informa UK Limited. DOI: <<http://dx.doi.org/10.1080/07373937.2018.1492614>>.

VILELA, Duarte; FERREIRA, Reinaldo de Paula; FERNANDES, Elizabeth Nogueira; JUNTOLLI, Fabricio Vieira (ed.). **Pecuária de leite no Brasil: cenários e avanços tecnológicos**. Brasília: Embrapa, 2016. 435 p. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/164236/1/Pecuaria-de-leite-no-Brasil.pdf>>. Acesso em: 19 maio 2022.

WANG, Jintao; LOVARELLI, Daniela; ROTA, Nicola; SHEN, Mingxia; LU, Mingzhou; GUARINO, Marcella. The Potentialities of Machine Learning for Cow-Specific Milking: automatically setting variables in milking machines. **Animals**, [S.L.], v. 12, n. 13, p. 1614, 23 jun. 2022. MDPI AG. DOI: <<http://dx.doi.org/10.3390/ani12131614>>.

WINSTEN, Jonathan R.; PARSONS, Robert L.; HANSON, Gregory D. A Profitability Analysis of Dairy Feeding Systems in the Northeast. **Agricultural And Resource Economics Review**, [S.L.], v. 29, n. 2, p. 220-228, out. 2000. Cambridge University Press (CUP). DOI: <<http://dx.doi.org/10.1017/s1068280500005359>>.

ZHU, Ning; WANG, Kai; ZHANG, Shun-Liang; ZHAO, Bing; YANG, Jun-Na; WANG, Shou-Wei. Application of artificial neural networks to predict multiple quality of dry-cured ham based on protein degradation. **Food Chemistry**, [S.L.], v. 344, p. 128586, maio 2021. Elsevier BV. DOI: <<http://dx.doi.org/10.1016/j.foodchem.2020.128586>>.