



GUSTAVO ALVES DE MELO

**ANÁLISE COMPARATIVA DE EFICIÊNCIA NA PECUÁRIA
LEITEIRA: IDENTIFICANDO AS POSSIBILIDADES DE
SUCESSO**

**LAVRAS-MG
2024**

GUSTAVO ALVES DE MELO

**ANÁLISE COMPARATIVA DE EFICIÊNCIA NA PECUÁRIA LEITEIRA:
IDENTIFICANDO AS POSSIBILIDADES DE SUCESSO**

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Administração, área de concentração em Estratégia de Negócios Globais e Finanças Corporativas, para a obtenção do título de Doutor.

Prof. Dr. Luiz Gonzaga de Castro Júnior
Orientador

Prof (a). Dr (a). Maria Gabriela Mendonça Peixoto
Coorientadora

**LAVRAS-MG
2024**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Melo, Gustavo Alves de.

Análise Comparativa de eficiência na pecuária leiteira: :
Identificando as possibilidades de sucesso / Gustavo Alves de Melo.
- 2024.

150 p. : il.

Orientador(a): Luiz Gonzaga de Castro Júnior.

Coorientador(a): Maria Gabriela Mendonça Peixoto.

Tese (doutorado) - Universidade Federal de Lavras, 2024.

Bibliografia.

1. Gestão de Desempenho. 2. Pecuária. 3. Previsão. I. Júnior,
Luiz Gonzaga de Castro. II. Peixoto, Maria Gabriela Mendonça. III.
Título.

GUSTAVO ALVES DE MELO

**ANÁLISE COMPARATIVA DE EFICIÊNCIA NA PECUÁRIA LEITEIRA:
IDENTIFICANDO AS POSSIBILIDADES DE SUCESSO**

***COMPARATIVE ANALYSIS OF EFFICIENCY IN DAIRY FARMING: IDENTIFYING
THE POSSIBILITIES OF SUCCESS***

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Administração, área de concentração em Estratégia de Negócios Globais e Finanças Corporativas, para a obtenção do título de Doutor.

APROVADA em 21 de agosto de 2024.

Dr. Samuel Borges Barbosa	UFV
Dr(a). Jaqueline Severino da Costa	UFLA
Dr. Thiago Henrique Nogueira	UFV
Dr(a). Maria Cristina Angélico Mendonça	UFLA
Dr. Magno Alves de Oliveira	UFV

Dr. Luiz Gonzaga de Castro Júnior
Orientador

Dr (a). Maria Gabriela Mendonça Peixoto
Coorientadora

**LAVRAS-MG
2024**

Aos meus pais, avó, irmã e sobrinha.

Dedico

AGRADECIMENTOS

Inicialmente, gostaria de agradecer à Deus por me conceder saúde e determinação para enfrentar todos os desafios até aqui. Aos meus pais, Nei e Rosilene, pelo apoio incondicional em toda minha trajetória de vida. À minha irmã Lorena, que nunca mediu esforços para me ajudar em todas as situações. À minha avó Cleunice, por sempre ter acreditado em meu potencial, me incentivando a seguir em frente a cada conquista! Aos demais familiares, que mesmo distantes, sempre torceram pelo meu sucesso!

Aos meus amigos do Departamento de Gestão do Agronegócio da Universidade Federal de Lavras – UFLA e do Centro de Inteligência em Agronegócios - CIAgros pela parceria, apoio e amizade construídos. Aos meu orientador, Dr. Luiz Gonzaga de Castro Júnior pela paciência, compromisso e auxílio concedidos nesta etapa de minha vida. À minha coorientadora Dra. Maria Gabriela Mendonça Peixoto pela confiança, parceria, amizade e compromisso estabelecidos desde o ano de 2016, quando nos conhecemos em minha graduação.

À Universidade Federal de Lavras – UFLA, ao Departamento de Administração e Economia (DAE), ao Departamento de Gestão do Agronegócio (DGA) e ao Programa de Pós-Graduação em Administração - PPGA/UFLA pela oportunidade de realização do doutorado. Em especial gostaria de agradecer ao antigo coordenador Dr. Daniel Carvalho de Resende e atual Dr. Luiz Henrique de Barros Vilas Boas por todo auxílio nesse período. Gostaria de agradecer também à FAPEMIG, pois o “presente trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG)”.

Aos membros de minhas bancas de defesa de qualificação e tese, em especial aos professores Dr. Marcelo Carneiro Gonçalves, Dr. Francisco Rodrigues Lima Junior, Dr(a). Maria Cristina Angélico Mendonça, Dr. Thiago Henrique Nogueira, Dr(a) Jaqueline Severino da Costa, Dr. Magno Alves de Oliveira e Dr. Samuel Borges Barbosa, pelas considerações feitas em minha pesquisa, contribuindo de forma efetiva para a realização deste trabalho.

Aos meus colegas do PPGA/UFLA e amigos feitos neste período de doutorado, gostaria de agradecer pelos bons momentos compartilhados, pelas trocas de experiências e auxílio ao longo dessa jornada.

Muito obrigado!

“O segredo do sucesso é a constância no objetivo.” - *Benjamin Disraeli*

RESUMO

O leite corresponde a um dos produtos de maior consumo no mundo. Além de ser essencial nas primeiras etapas de vida do ser humano, o leite também tem forte representatividade no contexto econômico. Logo, são diversas as famílias de pequenos e médios produtores que dependem da sua produção para geração de renda. No Brasil, um dos maiores produtores mundiais, a produção se concentra nos estados de Minas Gerais e Paraná. Fatores como o manejo adequado, boas práticas de gestão da produção e inserção de tecnologias tem sido responsáveis por elevar a qualidade e a produtividade do leite, marcando uma nova fase da pecuária leiteira no país. Todavia, o clima tem sido um fator agravante para o setor, a partir da alteração da temperatura global e extensão dos períodos de seca. Isso porque os animais dependem de uma temperatura adequada para a produção, e sua alimentação é dependente da produção de grãos comprometida pela falta de chuvas. Desta forma, altos custos de produção e uma queda na quantidade produzida são observados. Neste sentido, o objetivo deste estudo foi avaliar o desempenho das regiões produtoras de leite no Brasil em 2022 a partir da utilização das técnicas de Análise de Componentes Principais (PCA), Análise Envoltória de Dados (DEA), Simulação de Monte Carlo (SMC) e Redes Neurais Artificiais (RNA). Para tanto, o estudo seguiu os moldes de uma pesquisa descritiva, com abordagem quantitativa e lógica indutiva. O prazo de realização do estudo foi de 24 meses e foi utilizado os *softwares R-Project 3.2.2* e *RStudio 2023.12.0+369* para apoio na aplicação das técnicas. Os resultados destes estudo apontaram que apenas 35% dos produtores obtiveram eficiência técnica pura máxima, sendo que cerca de 91% do total de produtores apresenta áreas de produção inferior a 100 hectares. A etapa probabilística forneceu insights valiosos, a partir dos melhores ajustes das variáveis do modelo com base nas funções Log-Logística, Pearson e Log-Normal. Já os resultados da aplicação da técnica de RNA indicaram um bom desempenho da rede neural para a classificação mensal da dinâmica de preços do leite com uma acurácia de 87,7%, precisão de 86,57% e erro quadrático médio (MSE) de 0,1229. Espera-se que este estudo forneça uma base de conhecimento sólida do setor para as partes interessadas, bem como ampare a tomada de decisão de produtores e/ou gestores em suas propriedades.

Palavras-chave: Gestão de Desempenho; Pecuária; Leite; Benchmarks; Previsão.

ABSTRACT

Milk is one of the most consumed products in the world. In addition to being essential in the early stages of human life, milk also has a strong presence in the economic context. Consequently, many families of small and medium producers depend on its production for income generation. In Brazil, one of the world's largest producers, production is concentrated in the states of Minas Gerais and Paraná. Factors such as proper management, good production management practices, and the introduction of technologies have been responsible for raising the quality and productivity of milk, marking a new phase in dairy farming in the country. However, the climate has been a worsening factor for the sector, due to global temperature changes and extended periods of drought. This is because the animals depend on adequate temperatures for production, and their feed relies on grain production, which is compromised by the lack of rain. Thus, high production costs and a decrease in production quantity are observed. In this context, this study aimed to evaluate the performance of milk-producing regions in Brazil in 2022 using Principal Component Analysis (PCA), Data Envelopment Analysis (DEA), Monte Carlo Simulation (MCS), and Artificial Neural Networks (ANN). To this end, the study followed the standards of descriptive research, with a quantitative approach and inductive logic. The study was conducted over 24 months, using the *software* R-Project 3.2.2 and RStudio 2023.12.0+369 to support the application of the techniques. The results of this study showed that only 35% of producers achieved maximum pure technical efficiency, with about 91% of the total number of producers having production areas smaller than 100 hectares. The probabilistic stage provided valuable insights from the best adjustments of the model variables based on the Log-Logistic, Pearson, and Log-Normal functions. The results of the ANN technique application indicated good performance of the neural network for the monthly classification of milk price dynamics, with an accuracy of 87.7%, precision of 86.57%, and a mean squared error (MSE) of 0.1229. It is expected that this study will provide a solid knowledge base for the sector's stakeholders, as well as support the decision-making of producers and/or managers on their properties.

Keywords: Performance Management; Livestock; Milk; Benchmarks; Forecasting.

INDICADORES DE IMPACTO

A pecuária de leite tem grande representatividade no contexto da produção global de alimentos. Além de ser essencial nas primeiras etapas de vida do ser humano, o leite também tem forte representatividade no contexto econômico. Logo, são diversas as famílias de pequenos e médios produtores que dependem da sua produção para geração de renda. No Brasil, um dos maiores produtores mundiais, a produção se concentra nos estados de Minas Gerais e Paraná. Fatores como o manejo adequado, boas práticas de gestão da produção e inserção de tecnologias tem sido responsáveis por elevar a qualidade e a produtividade do leite, marcando uma nova fase da pecuária leiteira no país. Todavia, o clima tem sido um fator agravante para o setor, a partir da alteração da temperatura global e extensão dos períodos de seca. Isso porque os animais dependem de uma temperatura adequada para a produção, e sua alimentação é dependente da produção de grãos comprometida pela falta de chuvas. Desta forma, altos custos de produção e uma queda na quantidade produzida são observados. Neste sentido, o objetivo deste estudo foi avaliar o desempenho das regiões produtoras de leite no Brasil em 2022 a partir da utilização das técnicas de Análise de Componentes Principais (PCA), Análise Envoltória de Dados (DEA), Simulação de Monte Carlo (SMC) e Redes Neurais Artificiais (RNA). Para tanto, foram analisados um conjunto amostral de 864 produtores pertencentes à 18 estados brasileiros correspondentes à base de dados da Companhia do Leite do Brasil. Neste sentido, a sustentabilidade de famílias produtoras e o beneficiamento da segurança alimentar podem ser interpretados como impactos sociais deste estudo. No campo tecnológico, este estudo ressalta a importância de tecnologias como as Redes Neurais Artificiais para a otimização e previsão de preços no setor lácteo, bem como a incorporação de tecnologias de gestão e manejo adequado dos rebanhos como fator impulsionador da produtividade e qualidade do leite. Considerando que apenas 35% dos produtores atingiram a eficiência técnica máxima, este estudo promove impactos econômicos relacionados a otimização da produção e redução de custos. No âmbito cultural este estudo promoveu impactos na valorização do conhecimento técnico e ampliou a discussão sobre a combinação de técnicas tradicionais e inovadoras na pecuária leiteira moderna. Em suma, os impactos percebidos foram em potencial, necessitando que os produtores e gestores apliquem as recomendações e práticas sugeridas pelo estudo para que se concretizem. Este estudo também possui um caráter extensionista dedicado a busca de avanços em tecnologia e produção na pecuária leiteira para este conjunto de produtores. Por fim, este estudo esteve alinhado aos Objetivos de Desenvolvimento Sustentável (ODS) da Organização das Nações Unidas (ONU), a saber, Erradicação da pobreza, Fome zero e agricultura sustentável, Saúde e Bem-estar, Trabalho decente e crescimento econômico, Indústria, Inovação e Infraestrutura, Redução das desigualdades, Consumo e produção responsáveis e Vida terrestre.

IMPACT INDICATORS

Dairy farming holds significant importance in the context of global food production. In addition to being essential during the early stages of human life, milk also has strong economic relevance. Thus, numerous small and medium-sized producers' families rely on its production to generate income. In Brazil, one of the world's largest producers, production is concentrated in Minas Gerais and Paraná. Factors such as proper management, good production management practices, and the adoption of technologies have been responsible for increasing the quality and productivity of milk, marking a new phase in the country's dairy farming. However, climate has aggravated the sector due to global temperature changes and prolonged drought periods. This is because animals require an adequate temperature for production, and their feed depends on grain production, which is compromised by the lack of rain. As a result, high production costs and a decrease in the quantity produced have been observed. In this context, the objective of this study was to evaluate the performance of milk-producing regions in Brazil in 2022 using techniques such as Principal Component Analysis (PCA), Data Envelopment Analysis (DEA), Monte Carlo Simulation (MCS), and Artificial Neural Networks (ANN). To this end, a sample of 864 producers from 18 Brazilian states corresponding to the database of the Brazilian Milk Company was analyzed. In this sense, the sustainability of producing families and the improvement of food security can be interpreted as social impacts of this study. In the technological field, this study highlights the importance of technologies such as Artificial Neural Networks for optimizing and forecasting prices in the dairy sector, as well as the incorporation of management technologies and proper herd management as a driving factor for milk productivity and quality. Considering that only 35% of producers achieved maximum technical efficiency, this study promotes economic impacts related to optimizing production and reducing costs. Culturally, this study has promoted the appreciation of technical knowledge and expanded the discussion on combining traditional and innovative techniques in modern dairy farming. In summary, the impacts perceived were potential, requiring producers and managers to apply the recommendations and practices suggested by the study for them to be realized. This study also has an extensionist character, dedicated to seeking advances in technology and production in dairy farming for this group of producers. Finally, this study was aligned with the United Nations (UN) Sustainable Development Goals (SDGs), namely, No Poverty, Zero Hunger and Sustainable Agriculture, Good Health and Well-being, Decent Work and Economic Growth, Industry, Innovation, and Infrastructure, Reduced Inequality, Responsible Consumption and Production, and Life on Land.

LISTA DE FIGURAS (PRIMEIRA PARTE)

Figura 1 – Modelo <i>free stall</i> para a produção do leite.....	27
Figura 2 – Tripé de sustentabilidade.....	36
Figura 3 – Diagrama de fluxo para tomada de decisão na pecuária leiteira.....	39
Figura 4 – Métodos de tomada de decisão na produção de leite.....	40
Figura 5 - Exemplo prático da análise SWOT na pecuária leiteira.....	42
Figura 6 - Estrutura da pecuária leiteira.....	44
Figura 7 - Hierarquia de aprendizado na pecuária leiteira.....	46
Figura 8 - Estrutura de um neurônio biológico.....	62
Figura 9 - Rede <i>perceptron</i> simples.....	62
Figura 10 - Rede <i>perceptron</i> multicamadas.....	63
Figura 11 - Fases de treinamento da rede <i>perceptron</i> multicamadas.....	64
Figura 12 - Método de validação cruzada com k subconjuntos.....	66
Figura 13 - Comportamento da rede <i>perceptron</i> multicamadas em <i>overfitting</i>	67
Figura 14 - Matriz de confusão.....	69
Figura 15 - Interrelação entre técnicas de análise.....	73

LISTA DE FIGURAS (SEGUNDA PARTE – ARTIGO 1)

Figura 1 - Modelo proposto para avaliação da eficiência da pecuária leiteira no Brasil.....	92
Figura 2 - Diagrama de ordenação de variáveis originais para PC I e PC II.....	100
Figura 3 - Diagrama de ordenação de variáveis originais para PC II e PC III.....	102
Figura 4 - Escores de eficiência técnica pura dos 57 produtores.....	104
Figura 5 - Alvos para os inputs.....	105
Figura 6 - Alvos para os outputs.....	106
Figura 7 - Área das propriedades (ha).....	117

LISTA DE FIGURAS (SEGUNDA PARTE – ARTIGO 2)

Figura 1 - Componentes de uma rede neural artificial multicamadas.....	129
Figura 2 - Modelo conceitual das etapas de pesquisa.....	130
Figura 3 - Algoritmo para o modelo de redes neurais artificiais.....	132
Figura 4 - Arquitetura de uma rede <i>perceptron</i> multicamadas.....	135

LISTA DE TABELAS (SEGUNDA PARTE – ARTIGO 1)

Tabela 1 - Indicadores para avaliação de desempenho de propriedades leiteiras	92
Tabela 2 - Primeiras variáveis originais mais correlacionadas com PC I, PC II e PC III	97
Tabela 3 - Matriz de correlação de variáveis originais.....	98
Tabela 4 - Relação de autovetores (\hat{e}) e correlações (r) entre PC I, PC II e PC III e as variáveis	99
Tabela 5 – Benchmarks	109
Tabela 6 - Descrição de dados para produtores eficientes	111
Tabela 7 - Comparações de ajustes para variáveis do modelo	113
Tabela 8 - Inputs do modelo de simulação	113
Tabela 9 - Outputs do modelo de simulação	114

LISTA DE TABELAS (SEGUNDA PARTE – ARTIGO 2)

Tabela 1 - Descrição de inputs e outputs da rede	130
Tabela 2 - Resultados da etapa de treinamento da rede.....	136
Tabela 3 - Resultados da etapa de teste da rede	137
Tabela 4 - Matriz de confusão	138
Tabela 5 - Resultados da etapa de previsão para 10 casos	138

LISTA DE SIGLAS

ACV	Análise do Ciclo de Vida
AUC	Área sob a Curva Característica de Operação do Receptor
BCB	Banco Central do Brasil
BCC	<i>Banker, Charnes e Cooper</i>
CCR	Charnes, Cooper e Rhodes
CEPEA	Centro de Estudos Avançados em Economia Aplicada
COE	Custo Operacional Efetivo
COT	Custo Operacional Total
CT	Custo Total
CP1	Componente Principal 1
CP2	Componente Principal 2
CP3	Componente Principal 3
DEA	<i>Data Envelopment Analysis</i>
DMUs	<i>Decision Making Units</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
KPIs	Key Performance Indicators
KS	Kolmogorov-Smirnov
MAPA	Ministério da Agricultura, Pecuária e Abastecimento
PCA	<i>Principal Components Analysis</i>
PGPM	Política de Garantia de Preços Mínimos
PMC	<i>Perceptron</i> Multicamadas
PNQL	Plano Nacional de Melhoria da Qualidade do Leite
RNA	Rede Neural Artificial
ROC	Característica de Operação do Receptor
SMC	Simulação de Monte Carlo

SUMÁRIO

PRIMEIRA PARTE	16
1 INTRODUÇÃO	17
1.1 Contextualização	17
1.2 Problema de pesquisa	18
1.3 Objetivos	19
1.3.1 Objetivo Geral	19
1.3.2 Objetivos Específicos	19
1.4 Justificativa	20
1.5 Estrutura da tese	23
2 REFERENCIAL TEÓRICO	24
2.1 Gestão de desempenho no agronegócio e na pecuária leiteira	24
2.2 Métodos de tomada de decisão aplicados a produção de leite	38
2.3 Contextualização da produção de leite	48
2.4 Técnicas de apoio a tomada de decisão	55
2.4.1 Análise de Componentes Principais (PCA)	55
2.4.2 Análise Envolvória de Dados (DEA)	57
2.4.3 Simulação de Monte Carlo (SMC)	60
2.4.4 Redes Neurais Artificiais (RNAs)	61
3 PROCEDIMENTOS METODOLÓGICOS	71
3.1 Tipo de pesquisa	71
3.2 Objeto de estudo e amostragem	71
3.3 Procedimentos e técnicas de coleta de dados	72
3.4 Análise e interpretação dos dados	73
REFERÊNCIAS	77
SEGUNDA PARTE - ARTIGOS	87
ARTIGO 1 – BENCHMARKS PROBABILÍSTICOS AUMENTAM A EFICIÊNCIA DA PECUÁRIA LEITEIRA	88
1 INTRODUÇÃO	89
2 METODOLOGIA	92
3 RESULTADOS	97
3.1 Seleção e classificação de variáveis em inputs e outputs para avaliação do desempenho das propriedades leiteiras	97
3.2 Análise de Componentes Principais aplicada as propriedades leiteiras do Brasil ..	99
3.3 Análise da eficiência técnica pura e alvos	103

3.4	Proposição e avaliação de cenários para propriedades ineficientes	111
4	DISCUSSÃO.....	116
5	CONSIDERAÇÕES FINAIS	120
	REFERÊNCIAS	122
	ARTIGO 2 – PREVISÃO DE OSCILAÇÕES NO PREÇO DO LEITE PROMOVE A PERMANÊNCIA DE PEQUENOS E MÉDIOS PRODUTORES NO SETOR..	125
1	INTRODUÇÃO.....	126
2	METODOLOGIA	129
3	RESULTADOS.....	135
4	DISCUSSÃO.....	140
5	CONSIDERAÇÕES FINAIS	144
	TERCEIRA PARTE – CONSIDERAÇÕES FINAIS.....	149
	CONSIDERAÇÕES FINAIS	150

PRIMEIRA PARTE

Nesta parte são expostos os tópicos gerais do trabalho, que norteiam a pesquisa como um todo e embasam os artigos expostos na segunda parte.

1 INTRODUÇÃO

Neste tópico foi abordada uma breve contextualização da pecuária leiteira global, o problema de pesquisa, objetivos geral e específicos e a justificativa do projeto. Por fim, foi apresentada a estrutura de construção deste estudo.

1.1 Contextualização

A pecuária de leite tem grande representatividade no contexto da produção global de alimentos (Arvidsson Segerkvist *et al.*, 2020). Trata-se de um setor diverso que integra desde pequenos e médios produtores até grandes propriedades com padrões industriais (Cabrera; Fadul-Pacheco, 2021). Além de ser uma atividade econômica com uma barreira de entrada reduzida, o que facilita a entrada de pequenos produtores, trata-se de uma atividade geradora de renda para muitas famílias ao longo da cadeia de valor (Feil *et al.*, 2023). Em razão da existência de um vasto conjunto de produtos derivados do leite, há uma necessidade contínua de mão de obra para a atuação em diversos elos da cadeia de produção destes produtos (Beber; Lakner; Skevas, 2021).

O avanço de boas práticas de produção de caráter sustentável aliadas ao bem-estar animal configuram alguns dos temas de interesse da pecuária de leite moderna (Cabrera; Fadul-Pacheco, 2021). Dessa forma, trabalhar alternativas de produção economicamente viáveis, com o mínimo de impacto possível ao meio ambiente e que garantam o bem-estar animal tem sido uma postura cada vez mais incentivada (Soteriades *et al.*, 2020). Vale ressaltar o impacto negativo que as mudanças climáticas provocam no setor, onerando a produção e inviabilizando a permanência do pequeno produtor na atividade (Puupponen *et al.*, 2022).

Neste contexto, o desafio é encontrar alternativas de produção que integrem o pequeno, médio e grande produtor na atividade, tornando o setor mais competitivo (Martinelli *et al.*, 2022). Dessa maneira, incentivos de produção poderão ser obtidos por todas as propriedades, possibilitando a evolução de pequenos produtores no setor com maior conhecimento e infraestrutura (Beber; Lakner; Skevas, 2021). A inserção de práticas sustentáveis também configura um desafio, pois grande parte das propriedades leiteiras existentes ainda utilizam métodos convencionais de manejo e produção (Feil *et al.*, 2023).

Na perspectiva do consumidor, o leite representa uma das principais fontes de proteína e de outros nutrientes importantes para o desenvolvimento dos seres humanos (Givens *et al.*, 2020). Sendo assim, a pecuária de leite também está associada à segurança alimentar e

nutricional (Erickson; Kalscheur, 2020). Com uma demanda por produtos lácteos em expansão impulsionada pelo crescimento populacional e novos hábitos alimentares é fundamental que medidas de apoio ao setor sejam tomadas a fim de solucionar os desafios aqui apresentados.

1.2 Problema de pesquisa

A queda na produção de leite no Brasil tem ocorrido de forma gradativa nos últimos anos (IBGE, 2023). Isto se deve boa parte ao aumento verificado nos custos de produção, que dificulta a permanência dos pequenos e médios produtores na atividade (Feil *et al.*, 2023). A falta de chuvas compromete as plantações de insumos básicos como, milho e soja, para a alimentação dos animais (Feil *et al.*, 2023). Neste contexto, acentua-se o grave impacto das mudanças climáticas na pecuária leiteira (Puupponen *et al.*, 2022). Em 2022, no Brasil, houve uma queda no valor de produção em razão do aumento dos custos e redução das margens de produtores, representou uma queda de 1,6% e um valor total estimado de 34,6 bilhões de litros (IBGE, 2023).

A falta de acesso ao crédito também representa uma das dificuldades para o pequeno produtor (De Souza *et al.*, 2021). Muitos destes necessitam de apoio financeiro para a manutenção de seu rebanho e de suas plantações (Silveira *et al.*, 2022). Esta questão se agrava pela concentração de pequenos produtores na qual a pecuária leiteira no Brasil se caracteriza, criando entraves para a maior competitividade do setor (Gori Maia *et al.*, 2022).

A evolução tecnológica é um aspecto importante a ser ressaltado na pecuária leiteira, visto os grandes avanços do ponto de vista de seleção genética dos rebanhos, práticas inovadoras de manejo animal, e sistemas de gestão mais eficientes implementados em algumas propriedades do país (Fuentes *et al.*, 2020). Todavia, acompanhar as tendências do mercado tecnológico muitas vezes incorre em altos custos para o produtor e/ou gestor (Dutton-Register *et al.*, 2020). Nesta perspectiva, observa-se a sobreposição de fatores socioeconômicos na atividade pecuária, inviabilizando o aumento de desempenho de algumas propriedades (Martinelli *et al.*, 2022).

De fato, é necessário reconhecer avanços promissores quanto a modelos de produção pautados na sustentabilidade e bem-estar animal (Romaniuk *et al.*, 2021). Trata-se de alternativas econômicas de baixo impacto ao meio ambiente e que favorecem a maior produtividade dos animais (Leitgeb *et al.*, 2023). No entanto, é uma realidade que ainda não faz parte de muitas propriedades leiteiras no país. Dito isso, criar possibilidades de melhorias para

a pecuária leiteira no país que aliem o aumento da produção a sustentabilidade ambiental é visto como uma alternativa economicamente promissora e desafiante (Feil *et al.*, 2023).

Neste sentido, o estudo avança na perspectiva de contribuir no processo de expansão da produção no setor a partir de práticas economicamente viáveis e sustentáveis para todas as classes de produtores. Além disso, este estudo se apoia em uma análise da eficiência técnica pura de propriedades leiteiras. Trata-se de uma busca pela maior eficiência operacional da cadeia produtiva do leite. Para tanto, metodologicamente, este estudo propõe a aplicação da Análise de Componentes Principais (PCA) como estratégia de redução dimensional de variáveis originais. Em seguida avança com a aplicação da Análise Envoltória de Dados (DEA) a partir da identificação de propriedades ineficientes. Logo, é viabilizada a aplicação da Simulação de Monte Carlo (SMC) para as propriedades ineficientes de acordo com as variáveis originais utilizadas. De forma complementar, o estudo ainda se dedica a aplicação das Redes Neurais Artificiais (RNAs) para a previsão da ocorrência de aumentos ou reduções no preço do leite a partir das variáveis originais de análise.

Para tanto, o estudo apresenta duas questões de pesquisa: Quais os indicadores mais impactantes no desempenho das propriedades leiteiras estudadas? Como a mensuração dos escores de eficiência aliada às técnicas de simulação e redes neurais artificiais podem contribuir para o aumento do desempenho destas propriedades?

1.3 Objetivos

Esta seção se dedicou a apresentação dos objetivos geral e específicos do estudo.

1.3.1 Objetivo Geral

O objetivo geral deste estudo foi avaliar o desempenho das regiões produtoras de leite no Brasil em 2022 a partir da utilização das técnicas PCA, DEA, SMC e RNAs.

1.3.2 Objetivos Específicos

- Contextualizar as regiões produtoras do leite no Brasil;
- Selecionar inputs e outputs e gerar indicadores de desempenho globais, a partir da primeira, segunda e terceira componentes principais;
- Medir a eficiência técnica pura, por meio do apoio em indicadores de desempenho;

- Propor benchmarks determinísticos e probabilísticos para produtores de leite que apresentem fontes de ineficiência de desempenho;
- Trabalhar mecanismos para a previsão de preço do leite na pecuária leiteira a partir da técnica de Redes Neurais Artificiais;
- Discutir e propor insights informados na tentativa de contribuir com o aumento do desempenho das regiões produtoras, considerando sua estrutura, características regionais e recursos disponíveis.

1.4 Justificativa

O leite consiste em um alimento saudável, rico em nutrientes e essencial para o desenvolvimento dos seres humanos principalmente nos primeiros estágios de vida (Givens *et al.*, 2020). Além de ser um dos produtos de maior consumo registrado no mundo, trata-se da base para fabricação de diversos outros produtos como, manteiga, iogurte, queijos, doces, pães, bolos, entre outros (Wankar; Rindhe; Doijad, 2021). Tal fato indica sua abrangência e forte participação no setor alimentício, logo, alterações de preço ou até a falta deste produto pode inviabilizar a produção de derivados e acarretar danos a economia (Cabrera; Fadul-Pacheco, 2021).

Do ponto de vista climático, o Brasil possui forte aptidão para o desenvolvimento da pecuária leiteira (Gori Maia *et al.*, 2022). Isso se deve a um clima tropical que se adequa a zona de conforto para a produção dos animais, bem como para a produção de grãos e forrageiras necessários para a alimentação destes (Siqueira *et al.*, 2021). Acentua-se aqui o trabalho desempenhado por muitos médicos veterinários e zootecnistas no país em prol de um manejo adequado, que garanta o bem-estar dos animais e, conseqüentemente, aumentos de produtividade (Martinelli *et al.*, 2022).

No Brasil, as regiões Sul e Sudeste se destacam na atividade, sendo Paraná e Minas Gerais os estados com maior produção de leite (IBGE, 2023). Em 2022, Paraná apresentou um valor de produção de aproximadamente R\$ 11,0 bilhões, já Minas Gerais um valor um pouco acima de R\$ 22,0 bilhões (IBGE, 2023). Todavia, o que se observa é um aumento do preço do leite e uma queda da quantidade produzida (IBGE, 2023). Isso ocorre, pois o pequeno e médio produtor enquanto dependentes da atividade para seu sustento e dotados de altos custos de produção, acabam por explorar alternativas mais lucrativas como, o próprio arrendamento de suas terras para a produção de alimentos (Siqueira *et al.*, 2021).

A pecuária leiteira tem enfrentado dificuldades para a estabilização dos custos de produção. Um dos fatores responsáveis trata-se dos impactos das mudanças climáticas percebidos nos últimos anos (De Souza *et al.*, 2021; Gori Maia *et al.*, 2022). Aumentos progressivos da temperatura global e da extensão dos períodos de seca são alguns dos principais responsáveis pela queda de produção dos animais (De Souza *et al.*, 2021). Além disso, tais fatores elevam os custos de produção, reduzindo as margens do pequeno produtor, podendo até inviabilizar sua permanência na atividade (Ruviaro *et al.*, 2020).

Desta forma, criar condições para que o pequeno e médio produtor se mantenham na atividade é fundamental para a manutenção de bons níveis de produção do leite, uma vez que grande parte das propriedades leiteiras no país se enquadram neste perfil (Ruviaro *et al.*, 2020; Zanin *et al.*, 2020). A utilização de técnicas avançadas de gestão é um caminho promissor e que gera benefícios neste sentido (Yu *et al.*, 2023). Logo, analisar o desempenho dos principais estados produtores de leite do Brasil é uma questão pertinente a ser estudada. Isso porque os dados apresentados poderão indicar através das variáveis consideradas qual a melhor decisão a ser tomada em cada propriedade ineficiente para uma produção mais eficiente, a custo reduzido e benéfica aos animais.

No âmbito acadêmico, a realização deste estudo pode favorecer a geração de insights para pesquisadores. Trata-se de um estudo focado em técnicas de tomada de decisão atuais e que podem trazer grandes contribuições gerenciais, sociais e teóricas (Feyissa *et al.*, 2023; Leitgeb *et al.*, 2023; Zheng *et al.*, 2023). Além disso, a pecuária leiteira trata-se de um setor que permite a aplicação de diferentes técnicas de pesquisa (Liu *et al.*, 2020; Lau *et al.*, 2022). Isso beneficia o alcance de avanços significativos para a atividade nos âmbitos econômico, social e ambiental (Soteriades *et al.*, 2020; Jebari *et al.*, 2022).

A gestão de desempenho apoiada pelas técnicas de Análise de Componentes Principais e Análise Envoltória de Dados podem contribuir para a manipulação do conjunto de variáveis originais, separando propriedades leiteiras eficientes de ineficientes, além de indicar seus respectivos pontos de melhoria e possíveis benchmarks. A aplicação da Análise de Componentes Principais na pecuária leiteira pode auxiliar na identificação de fatores influentes no setor, de modo a facilitar a tomada de decisões estratégicas e a alocação eficiente de recursos (de Lima Santos *et al.*, 2021).

Por exemplo, Dittrich *et al.* (2021) aplicaram a técnica de Análise de Componentes Principais para identificar variáveis importantes que definem o comportamento de vacas leiteiras em propriedades da Alemanha. Os autores ainda avançaram na perspectiva de definição de parâmetros de desempenho a fim de buscar contribuições relevantes para o ganho de

produtividade dos animais e proporcionar maior bem-estar destes (Dittrich *et al.*, 2021). No entanto, o estudo carece de discussões densas sobre alvos de eficiência e não trata de forma comparativa da eficiência em diferentes regiões de análise.

No que se refere a associação da Análise Envoltória de Dados à gestão de desempenho da pecuária leiteira, trata-se de uma técnica que possibilita de maneira clara a análise de eficiência de sistemas de produção no setor, promovendo a melhoria de processos e uma cultura de boas práticas na atividade (Siafakas *et al.*, 2019; Kovács; Szűcs, 2020). Ressalta-se aqui os avanços de cunho sustentável que têm sido alcançados com apoio desta técnica e trazem importantes contribuições para o setor, inclusive a partir da triangulação com outras técnicas como a Análise do Ciclo de Vida (ACV) (Soteriades *et al.*, 2020; Pedolin *et al.*, 2021; Barros *et al.*, 2022). No entanto, também não se observa nestes estudos avanços quanto a discussão de alvos de eficiência e, sobretudo, a preocupação quanto a mudança de cenários de ineficiência.

A técnica de Simulação de Monte Carlo por sua vez pode ser aplicada à pecuária leiteira para a avaliação de impacto de variáveis originais de cunho ambiental, econômico ou social na produção de leite (Godfrey, Ip e Nordblom, 2022). Isso agrega valor a análise de eficiência, de modo a escalonar as variáveis por impacto observado na produtividade de animais (Masello *et al.*, 2021). Vale ressaltar a grande contribuição desta técnica para a gestão da qualidade do leite, previsão de doenças e manejo de animais, como verificado nos estudos de Rasmussen *et al.* (2021), Masello *et al.* (2021) e Lau *et al.* (2022). Neste estudo, a simulação pode contribuir fornecendo insights detalhados em relação às unidades ineficientes, através de análises de sensibilidade e meta por exemplo.

Se tratando das Redes Neurais Artificiais aplicadas à pecuária leiteira, podem ser citados avanços na previsão de produção a partir de um conjunto de variáveis originais como alimentação, clima e genética de animais (Zheng *et al.*, 2023). Isso confere maior precisão na tomada de decisões no setor e favorece a otimização do gasto de recursos (Aklilu *et al.* 2021). Questões adicionais como a detecção de animais por imagem, monitoramento da saúde destes e previsão de escores de lactação também são alguns dos resultados obtidos por pesquisadores da área, como ocorrem nas pesquisas de Keceli *et al.* (2020), Achour *et al.* (2020), Liseune *et al.* (2021) e Tian *et al.* (2023). Assim, a utilização da técnica de Redes Neurais Artificiais pode enriquecer o modelo de análise de desempenho proposto conferindo um suporte adequado a todas as classes de produtores que almejam melhores oportunidades de negociação de sua produção, a partir da previsão de aumentos ou reduções do preço do leite.

1.5 Estrutura da tese

Este estudo foi estruturado em três partes. A primeira parte contemplou uma contextualização introdutória sobre a pecuária leiteira global, o problema de pesquisa, o objetivo geral e os objetivos específicos e, por fim, a justificativa do estudo. Logo após, dedicou-se a apresentação do referencial teórico. Em seguida a apresentação dos procedimentos metodológicos, onde foram abordados o tipo de pesquisa, o objeto de estudo e amostragem, os procedimentos e técnicas de coleta de dados e, por fim, como foi realizada a análise e interpretação destes dados. Assim, procedeu-se as considerações finais desta parte. Dando sequência ao estudo, foi desenvolvida a segunda parte, pautada na construção dos dois artigos como resultados deste estudo. Por fim, a terceira parte contemplou as considerações finais do estudo.

2 REFERENCIAL TEÓRICO

Esta seção se dedicou a fundamentação teórica de temas relacionados ao estudo. Os temas abordados foram: Gestão de desempenho no agronegócio e na pecuária leiteira; Métodos de tomada de decisão aplicados a produção de leite; Contextualização da produção do leite no Brasil; e Técnicas de apoio a tomada de decisão.

2.1 Gestão de desempenho no agronegócio e na pecuária leiteira

A gestão de desempenho trata-se de um campo de estudo que visa a melhoria das organizações em diferentes aspectos como produtividade e eficiência na utilização dos recursos disponíveis (Abane; Brenya, 2021). No entanto, uma gestão eficiente de desempenho depende do alinhamento entre os objetivos individuais e as metas organizacionais (Pavlov; Micheli, 2022). A avaliação de desempenho dos colaboradores, bem como a definição de expectativas e monitoramento contínuo são necessários neste contexto para o alcance de bons resultados (Almohtaseb *et al.*, 2020).

A avaliação de desempenho é um processo importante para as organizações, pois permite a identificação de falhas e pontos de melhoria das operações vigentes (Kadak; Laitinen, 2021). Acentua-se aqui a importância de feedbacks para a identificação ágil de áreas de melhoria e desenvolvimento da mão de obra (Nguyen *et al.*, 2023). A formação de fluxos de informação ao longo da cadeia de produção otimiza as operações a partir da redução dos tempos de setup e lead time por exemplo (Almohtaseb *et al.*, 2020). Além disso, a identificação de talentos é beneficiada por processos de comunicação eficiente nas organizações (Abane; Brenya, 2021).

A comunicação é um elemento essencial para a gestão de desempenho nas organizações. Isso porque ela estimula a integração da equipe, e sobretudo, fortalece as relações de liderança no ambiente de trabalho (Khaltar; Moon, 2020). Destaca-se a importância da comunicação direta e eficaz entre gestores e seus subordinados com a transferência de conhecimento e apoio técnico (Aftab *et al.*, 2022). Logo, esta integração permite o alcance de melhores níveis de desempenho de maneira mais facilitada, promovendo um ambiente mais confiante e comprometido com as metas organizacionais (Abane; Brenya, 2021).

O acesso a tecnologias e a implementação destas nos processos de gestão de desempenho das organizações confere agilidade na resolução de problemas (Khaltar; Moon, 2020). Equipes podem ser treinadas para a manipulação destas tecnologias, ampliando a rede

de conhecimento e reduzindo gargalos nas tomadas de decisão (Almohtaseb *et al.*, 2020). Ademais, a coleta de dados na organização é beneficiada com a criação de plataformas integradas de dados (Aftab *et al.*, 2022). Isso facilita a criação de relatórios de desempenho e automatiza o processo de avaliação, de modo que os gestores consigam otimizar seu tempo em prol do desenvolvimento de sua equipe (Nguyen *et al.*, 2023).

Os benefícios associados ao desenvolvimento de uma cultura de melhoria contínua pelas organizações contribui para a gestão eficiente de desempenho (Van Waeyenberg; Peccei; Decramer, 2022). A mudança recorrente dos objetivos organizacionais pode ser uma realidade estratégica para as organizações (Aftab *et al.*, 2022). Logo, uma gestão de desempenho flexível permite um melhor posicionamento da organização no mercado, aproveitando as oportunidades do setor e viabilizando o enfrentamento de desafios de forma mais dinâmica (Nguyen *et al.*, 2023).

No âmbito do agronegócio, a gestão de desempenho revela uma participação importante na garantia de eficiência e produtividade das operações (Mariyono, 2020). O agronegócio tem sido impactado pelas mudanças climáticas e sazonalidade de mercado. Desta forma, a gestão de desempenho no agronegócio pode consolidar o alinhamento de interesses individuais aos objetivos estratégicos do setor a fim de se obter uma produção estável e de qualidade (Ureña-Espaillet *et al.*, 2023). Considerando que se trata de um setor dinâmico, o monitoramento constante de resultados é uma prática que favorece o alcance destes objetivos (Leitão; Paiva; Thomé, 2024).

A capacitação de mão de obra nas propriedades confere maior competitividade ao setor e corresponde a um dos benefícios obtidos pela implementação de práticas de gestão de desempenho (Migdadi, 2022). O desenvolvimento de programas de treinamento específicos para manipulação de tecnologias, práticas avançadas de cultivo e gestão de recursos tem impacto na vida destes colaboradores, melhorando suas habilidades e incentivando as boas práticas de produção (Aftab *et al.*, 2022). Vale destacar aspectos de motivação e bem-estar como fatores complementares ao alcance de bons níveis de desempenho pelas propriedades (Mariyono, 2020).

Em termos de recursos, a gestão da cadeia de suprimentos apresenta impacto na gestão de desempenho no agronegócio (Okello; Lutah, 2022). Este setor é complexo e envolve uma multiplicidade de operações interrelacionadas (Giordano *et al.*, 2022). Para tanto, técnicas de avaliação de desempenho podem auxiliar na identificação de gargalos, sendo válida para a gestão eficaz das propriedades (Vanhuyse; Bailey; Tranter, 2021). A comunicação entre os elos

dessa cadeia de valor consolidam a gestão eficiente, e promove o alcance de bons resultados pautados em práticas agrícolas otimizadas (Okello; Luttag, 2022).

Abordar a sustentabilidade no contexto de gestão de desempenho no agronegócio também é uma questão importante (Ojo *et al.*, 2020). Com a ocorrência de eventos climáticos indesejáveis, a pressão por práticas agrícolas sustentáveis é maior (Arvidsson Segerkvist *et al.*, 2020). Dentre algumas medidas de produção agrícola sustentável podem ser listadas a rotação de culturas, métodos de conservação da água e solo, e o desenvolvimento de energia limpa (Arvidsson Segerkvist *et al.*, 2020; Jebari *et al.*, 2022). Além disso, a produção sustentável pode acarretar impactos no mercado, determinando o consumo de produtos pela população (Soteriades *et al.*, 2020; Jebari *et al.*, 2022).

No que se refere a pecuária leiteira, a gestão de desempenho envolve o monitoramento constante da saúde dos animais, operações de ordenha e qualidade do leite (Okello; Luttag, 2022). Logo, as práticas de gestão neste contexto quando bem implementadas podem reduzir custos, retrabalho, eliminação de gargalos, elevação do padrão de produção e aumento das margens dos produtores (Fuentes *et al.*, 2020). Para tanto, é necessário metas sejam definidas de acordo com a realidade das propriedades e que a capacitação de colaboradores seja considerada um investimento por produtores e/ou gestores (Kovács; Szűcs, 2020).


Estudos tem avançado na perspectiva da gestão de desempenho em propriedades leiteiras. Por exemplo, Oğuz e Yener (2019) examinaram a eficiência energética de produtos produzidos em empresas lácteas na região de Konya e forneceram sugestões para aumento da eficiência. Kovács e Szűcs (2020) exploraram a eficiência das propriedades leiteiras húngaras, a fim de determinar os fatores mais impactantes na produtividade dos animais. Ilyas *et al.* (2020) avaliaram a eficiência energética de sistemas de produção leiteira pastoril (PDFs) e celeiros (BDFs) na Nova Zelândia. Já Dittrich *et al.* (2021) extraíram informações de variáveis comportamentais e parâmetros de desempenho de vacas leiteiras em uma propriedade da Alemanha. Wairimu *et al.* (2021) caracterizaram inovações lácteas em propriedades leiteiras do Quênia. De Lima Santos *et al.* (2021) avaliaram os efeitos da torta de óleo de palma nos parâmetros de qualidade e produção do leite em vacas leiteiras.

Ainda no âmbito da gestão de desempenho na pecuária leiteira, Maina *et al.* (2020) concluíram em seu estudo sobre eficiência na pecuária leiteira que a redução de custos, a utilização adequada da mão-de-obra contratada e o uso intensivo da terra disponível para a produção do leite levariam a um aumento da eficiência econômica. Cardoso Consentini, Wiltbank e Sartori (2021) complementam em seu estudo sobre protocolos reprodutivos, a

importância de programas de inseminação artificial cronometrada para a construção de rebanhos de alta eficiência produtiva, nutricional e reprodutiva.

A saúde e bem-estar dos animais é um aspecto influente na qualidade e volume de leite produzido (Cardoso; Kalscheur; Drackley, 2020). Por isso, práticas de monitoramento da saúde destes animais devem ser realizadas com frequência, buscando adequações a rotina dos animais (Dittrich *et al.*, 2021). Fatores relacionados a nutrição adequada, manejo correto e controle de doenças podem ser trabalhados a partir deste monitoramento (Cardoso; Kalscheur; Drackley, 2020). A utilização de modelos de produção *free stall* ou de pastagem natural variam de acordo com as estratégias de produção em cada propriedade, no entanto, ressalta-se aqui o apelo de práticas de bem-estar animal para a maior produtividade dos animais (Dittrich *et al.*, 2021). A Figura 1 contempla um exemplo do modelo *free stall* para produção do leite.

Figura 1 – Modelo *free stall* para a produção do leite



Fonte: MilkPoint (2024)

O modelo *free stall* de produção compreende a construção de barracões de acondicionamento para os animais em lactação (Van Aken *et al.*, 2022). Neste sistema há o monitoramento da temperatura, o que favorece um ambiente controlado que reduz o estresse e a exposição dos animais às adversidades do clima (Pinheiro *et al.*, 2021). A alimentação também é controlada, com uma dieta balanceada para o atingimento de melhores níveis de produtividade por animal (Dimov *et al.*, 2021). A questão sanitária pode ser melhor trabalhada

neste modelo de produção, com o cumprimento de calendários de vacinação e combate a parasitas. No âmbito sustentável o modelo ainda promove o acúmulo de matéria orgânica que pode ser utilizada no preparo de adubo orgânico nas propriedades, reduzindo custos com adubação química de lavouras ou pastagens (Van Eerdenburg; Ruud, 2021).

No modelo tradicional de pastagem natural, os animais são expostos às volatilidades do clima, e realizam sua própria alimentação sem acompanhamento prévio (Dimov *et al.*, 2021). Dessa forma, trata-se de um sistema com menores custos de manutenção, entretanto, devido a maior exposição dos animais pode ser observado a ocorrência de um número maior de doenças e redução de produtividade por animal (Van Eerdenburg; Ruud, 2021). Os protocolos de acompanhamento reprodutivo dos animais também são diferenciados em relação ao modelo *free stall*, logo, as chances de insucesso reprodutivo e descarte de animais pode ser aumentada em um modelo de pastagem natural (Masello *et al.*, 2021).

A operação de ordenha consiste em uma das principais atividades nas propriedades leiteiras e que requer maior atenção (Ndambi *et al.*, 2020). Dessa forma, a gestão de desempenho pode beneficiar este processo a partir de práticas de manejo que maximizem a produção e reduzam o estresse dos animais (Edwards *et al.*, 2020). A utilização de novas tecnologias e automação agrega valor à produção, otimizando o processo de ordenha dos animais e melhorando a qualidade do leite produzido (Cardoso; Kalscheur; Drackley, 2020). Além disso, em termos financeiros a utilização de equipamentos na ordenha dos animais reduz custos operacionais de mão de obra, entretanto, elevam o nível de capacitação requerido para a atividade (Maina *et al.*, 2020).

Edwards *et al.* (2020) quantificaram a necessidade de mão-de-obra de ordenha em uma variedade de sistemas de produção leiteira baseados em pastagens e identificaram práticas ou tecnologias que facilitem uma ordenha eficiente. Ndambi *et al.* (2020) avaliaram a eficiência de diferentes sistemas de nutrição animal na produtividade de vacas leiteiras de propriedades da região central do Quênia. Já Ojo *et al.* (2020) ofereceram uma análise empírica do efeito do uso variável de insumos externos em propriedades leiteiras da União Europeia.

Se tratando da qualidade do leite, programas de controle de qualidade podem ser instaurados nas propriedades a fim de assegurar que o leite produzido possua todos os atributos necessários para o recebimento de certificações por exemplo (MAPA, 2024). Estes programas envolvem a contagem de células somáticas, níveis de bactérias, bem como a própria composição do leite, percentual de gordura, entre outros (MAPA, 2024). Trata-se de uma prática de gestão eficaz que auxilia na identificação e eliminação de problemas que possam afetar a qualidade do leite produzido (Rasmussen *et al.*, 2021). Ressalta-se aqui a eficácia da

identificação de animais doentes logo nos primeiros estágios da doença, favorecendo o diagnóstico rápido e a recuperação precoce dos animais (Rasmussen *et al.*, 2021).

A atualização do conhecimento de colaboradores pode gerar melhorias em diversas operações nas propriedades leiteiras, inclusive no processo de ordenha dos animais (Vanhuysse; Bailey; Tranter, 2021). Isso porque a capacitação e treinamento destes funcionários garante que estes considerem as melhores práticas de manejo, operação de equipamentos e gestão de qualidade em sua rotina de trabalho (Edwards *et al.*, 2020). Acentua-se aqui a importância na integração dos colaboradores e proprietários, pois isso permite maior engajamento da equipe, melhora a eficiência das operações e reduz custos do processo (Ojo *et al.*, 2020).

A medição de desempenho corresponde a um componente importante do processo de gestão de desempenho (Abane; Brenya, 2021). Trata-se de um processo que envolve a coleta e análise de dados relevantes de teor qualitativo ou quantitativo, e que permite o progresso organizacional (Pavlov; Micheli, 2022). Neste sentido as questões de eficiência e eficácia podem ser melhor trabalhadas nas organizações com o monitoramento de informações e a identificação de gargalos (Almohtaseb *et al.*, 2020). Informações como o nível de vendas, margem de lucro, satisfação do cliente e qualidade percebida do produto podem ser consideradas neste âmbito, representando um conjunto de indicadores de desempenho analisado (Kadak; Laitinen, 2021).

Os indicadores de desempenho ou KPIs (Key Performance Indicators) representam valores quantitativos que podem ser mensurados, comparados e monitorados a fim de obter um panorama de desempenho nas organizações (Kadak; Laitinen, 2021). Desta forma, uma organização ao apoiar-se no monitoramento de indicadores de desempenho passam a ter condições para a tomada de decisões mais informadas e representativas (Pavlov; Micheli, 2022). Algumas características devem ser levadas em consideração para a definição de KPIs, logo, estes devem ser mensuráveis, claros, relevantes e limitados a um conjunto representativo para o contexto de análise (Almohtaseb *et al.*, 2020).

O alinhamento entre os objetivos organizacionais e os indicadores de desempenho indicam coesão nos processos de gestão. Isso permite a atualização de estratégias e melhoria dos resultados organizacionais (Pavlov; Micheli, 2022). A utilização de KPIs promove uma cultura de melhoria contínua nas organizações de forma transparente (Nguyen *et al.*, 2023). Assim, todos os colaboradores entendem o objetivo principal da organização e trabalham suas metas individuais a fim de contribuir para seu alcance (Kadak; Laitinen, 2021).

A realização de benchmarking pode ser estimulada com a implementação de indicadores de desempenho. O benchmarking corresponde à comparação de desempenho de uma

organização com padrões ou melhores práticas do setor (Nguyen *et al.*, 2023). Ao identificar um distanciamento entre o desempenho esperado e alcançado a organização pode adotar novas medidas para seu crescimento (Almohtaseb *et al.*, 2020). Esta comparação pode incentivar a inovação e adoção de práticas mais eficientes no setor, bem como a definição de metas realistas e ambiciosas (Pavlov; Micheli, 2022).

Destaca-se a importância de tecnologias para a agilidade dos processos de monitoramento e tomada de decisão no âmbito da gestão de desempenho pautada em indicadores (Abane; Brenya, 2021). Além disso, a implementação eficaz de indicadores de desempenho depende do conhecimento dos objetivos estratégicos organizacionais (Kadak; Laitinen, 2021). Estes objetivos podem ser vinculados a classes de indicadores, logo, haverá indicadores de desempenho de produtividade, de qualidade, de capacidade e estratégicos por exemplo (Almohtaseb *et al.*, 2020).

Os indicadores de desempenho de produtividade auxiliam na gestão correta do uso de recursos nas organizações para a produção de bens e serviços (Nguyen *et al.*, 2023). Neste sentido, obter a informação de quão eficaz é a conversão de insumos em produtos na organização permite a avaliação do desempenho e atualização de melhorias dos processos organizacionais vigentes (Pavlov; Micheli, 2022). Alguns exemplos relacionam-se a taxa de receita por vendedor, horas trabalhadas em um projeto, índice de capacidade de resposta, taxa de clientes que deixaram a empresa, entre outros (Abane; Brenya, 2021).

Os indicadores de desempenho de qualidade se dedicam a entrega de valor ao cliente (Nguyen *et al.*, 2023). A partir deles é possível a identificação de erros e gargalos nas operações de produção que podem ser revistos ao longo do processo (Kadak; Laitinen, 2021). Ao realizar o monitoramento da qualidade dos bens e serviços oferecidos as organizações conseguem fidelizar clientes, obter eficiência nos processos e reduzir custos relacionados (Almohtaseb *et al.*, 2020). Dentre estes indicadores estão a porcentagem de produtos com defeito, índice de reclamações de clientes, eficiência e eficácia de produção, taxa de retrabalho, entre outros (Khaltar; Moon, 2020).

Os indicadores de desempenho de capacidade são responsáveis por gerenciar se as organizações possuem condições para a produção de uma quantidade desejada de produtos em um prazo definido (Abane; Brenya, 2021). Logo, conhecer os fatores limitantes da capacidade de produção permite que a organização atue otimizando o consumo de seus recursos e no melhor planejamento de suas operações (Kadak; Laitinen, 2021). Alguns indicadores de capacidade contemplam o tempo de ciclo de produção, a taxa de ocupação, a capacidade instalada versus utilizada, entre outros (Pavlov; Micheli, 2022).

Os indicadores de desempenho estratégicos indicam o posicionamento da organização perante seus objetivos (Almohtaseb *et al.*, 2020). Trata-se de indicadores de apoio a performance de cada estratégia adotada pela organização (Nguyen *et al.*, 2023). Além disso, são indicadores de avaliação estratégica que permitem o constante reajuste dos processos rumo aos objetivos organizacionais (Abane; Brenya, 2021). Métricas de crescimento organizacional, aumento da lucratividade, taxa de market share, retorno sobre investimento, entre outros podem ser considerados para este fim (Kadak; Laitinen, 2021).

No âmbito da pecuária leiteira, a utilização de indicadores de desempenho permite o acompanhamento das operações de produção do leite de forma eficiente (Van Eerdenburg; Ruud, 2021). Assim, é possível tomar decisões mais assertivas com relação a saúde e bem-estar dos animais, aumentos de produtividade e qualidade do leite (Cardoso; Kalscheur; Drackley, 2020). No entanto, deve-se ressaltar que esta prática de gestão necessita da capacitação e treinamento de colaboradores para que seja realizada a coleta de informações e geração de insights que contribuam para o bom desempenho das operações (Cardoso; Kalscheur; Drackley, 2020).

A produção de leite envolve uma sequência de processos que podem ser impactados por diferentes fatores como, clima, região, práticas de manejo e gestão, entre outros (Ba *et al.*, 2020; Liu *et al.*, 2020). Logo, a eficiência destes processos e da produção como um todo pode ser comprometida pela falta de atitudes adequadas neste contexto (Kovács; Szűcs, 2020). No âmbito genético, existem diferentes raças de bovinos pelo mundo, cada uma com características únicas de adaptação e produtividade (Liu *et al.*, 2020). Destacam-se as raças Holandesa, Jersey, Pardo Suíço, Gir, Guzerá, Sindi e Girolando que apresentaram uma boa adaptação ao clima tropical com bons níveis de produtividade (Liu *et al.*, 2020). Além disso, avanços consideráveis têm sido realizados com pesquisas em prol da seleção genética e geração de animais com linhagens de produção de alto padrão em todo mundo (Ba *et al.*, 2020).

Dentre os indicadores de produção, a quantidade de leite produzido por animal trata-se de uma variável de importância significativa para a comparação da produtividade entre animais (Liu *et al.*, 2020). Isso é útil para que produtores possam optar por raças de animais de maior custo-benefício, que produzam mais com o mesmo consumo de recursos (Kovács; Szűcs, 2020). Logo, o número de vacas em lactação pode ser afetado, por isso sugere-se o monitoramento deste indicador para a manutenção dos níveis de produção diária total nas propriedades (Ba *et al.*, 2020). Trata-se de um indicador que favorece a reposição do rebanho, a partir da identificação de animais ineficientes (Ba *et al.*, 2020).

A produção diária de uma propriedade associada a informações sobre o rebanho como o número de vacas em lactação, número total de vacas e total do rebanho permite que ajustes sejam realizados no manejo destes animais em prol de aumentos exponenciais de produção (Kovács; Szűcs, 2020). A área total de uma propriedade também é uma variável de impacto na produção do leite, principalmente em modelos de produção de pastagem natural (Ndambi *et al.*, 2020). Em períodos de clima seco, as pastagens sofrem com a falta de chuvas, reduzindo o nível proteico da matéria orgânica consumida pelos animais, reduzindo a produtividade destes (Givens *et al.*, 2020). Neste caso, produtores recorrem a suplementação dos animais a partir da utilização de concentrado, mineral e silagem que estimulam a lactação (Ba *et al.*, 2020).

Em modelos de pastagem natural, a taxa de lotação das pastagens corresponde a um indicador de interesse que promove o controle de bons níveis de pastagem para os animais (Givens *et al.*, 2020). Principalmente em períodos de seca extensos, manter o controle desta taxa possibilita que os produtores não elevem seus custos com suplementação animal. Todavia, trata-se de uma prática inviável para alguns pequenos e médios produtores que possuem áreas reduzidas de produção (Feil *et al.*, 2023). Acentua-se aqui a importância do planejamento prévio da atividade por estes produtores, a fim de evitar prejuízos ao longo do processo, relacionados a taxa de mortalidade dos animais e aumento dos custos de produção por exemplo (Kovács; Szűcs, 2020).

A relação entre as quantidades de leite produzido e o volume de concentrado e mineral para vacas em lactação trata-se de uma informação que orienta os produtores quanto a escolha da melhor suplementação animal (Givens *et al.*, 2020). Neste sentido, também ocorre a definição de suplementos animais de maior custo-benefício a fim de se aumentar as margens dos produtores. O controle do período de lactação dos animais pode auxiliar na redução dos custos associados a suplementação, a partir do descarte de animais com baixos volumes de produção diária (Givens *et al.*, 2020). Além disso, o encerramento do ciclo de lactação anual de cada animal deve ser acompanhado de forma a respeitar os intervalos mínimos entre gestações (Masello *et al.*, 2021). Isso permite que os animais se recuperem de um ciclo de produção, tendo subsídios de maior eficiência produtiva no próximo ciclo (Masello *et al.*, 2021).

A relação entre a quantidade de vacas em lactação, total de vacas e total do rebanho trata-se de indicadores zootécnicos que revelam a representatividade dos animais produtivos na propriedade (Cardoso; Kalscheur; Drackley, 2020). Assim, os produtores de posse destas informações podem organizar os protocolos reprodutivos dos animais, planejar a reposição de rebanho ou até a aquisição como estratégia de aumento dos níveis de produção do leite

(Arvidsson Segerkvist *et al.*, 2020). Este indicador também é interessante para a avaliação da eficiência de produção do rebanho, identificando animais que apresentam um ciclo de produção e reprodução adequado (Masello *et al.*, 2021). A produtividade da terra também contempla um indicador de sucesso nesse sentido, pois revela a eficiência dos recursos forrageiros utilizados na propriedade e do potencial do rebanho (Arvidsson Segerkvist *et al.*, 2020). Isso porque ao aumentar a taxa de lotação das pastagens e a produção de leite por animal, pode ser obtido uma maior produtividade da terra (Tassinari *et al.*, 2021).

A alimentação dos animais também é um fator influente na produção. Aqui acentua-se a substituição de alguns insumos por opções de maior custo-benefício por alguns produtores (Cardoso; Kalscheur; Drackley, 2020). Isso porque as mudanças climáticas têm sido responsáveis pela redução da produtividade das lavouras, ocasionando a perda da produção ou ineficiência dos plantios (Erickson; Kalscheur, 2020). Por outro lado, alterações na temperatura e umidade podem acarretar variações na quantidade de alimento consumido pelos animais (Guzmán-Luna *et al.*, 2022). Os sistemas de manejo também estão associados a dieta dos animais, haja vista que existem modelos de produção em que os animais são confinados em barracões sem que possam ir a pasto (*free stall*) e o modelo de produção a pasto com a soltura diária dos animais (Tassinari *et al.*, 2021).

Neste sentido, indicadores como os custos com concentrado e mineral para vacas em lactação e os custos com aleitamento podem ser listados como fontes de informação relevantes para a gestão nutricional dos rebanhos (Givens *et al.*, 2020). Trata-se de custos que representam grande parte da produção, logo, criar estratégias de redução deste quantitativo é essencial para a ampliação de margens dos produtores (Rasmussen *et al.*, 2021). Com a implementação destes indicadores viabiliza-se a adoção de diferentes modelos de produção, ou até a combinação de modelos (Jebari *et al.*, 2022). Em períodos de chuvas, as pastagens podem ser aproveitadas de uma melhor forma, com taxas de lotação controladas e alta rotatividade de exposição dos animais as pastagens, tais práticas favorecem o aumento da produtividade animal (Givens *et al.*, 2020).

Cabe lembrar que a saúde dos animais é vital para o alcance de melhorias na produtividade destes (Rasmussen *et al.*, 2021). Boas práticas de manejo são importantes para a prevenção de doenças bem como auxiliam na formalização de um cronograma sanitário, na determinação de uma frequência de ordenha e na manutenção do bem-estar animal (Rasmussen *et al.*, 2021). A falta de um manejo adequado pode ocasionar em estresse dos animais e perda de produtividade, além disso, alterações percebidas no clima podem contribuir negativamente neste contexto (Jebari *et al.*, 2022).

A prevenção de doenças e boas práticas de manejo podem ser monitoradas mediante o acompanhamento dos custos com medicamentos e curativos, taxa de vacinação, taxa de mortalidade, e rotatividade de uso de agentes químicos de combate a parasitoses (Garvey, 2022). A saúde das vacas impacta diretamente na qualidade do leite, por isso a consolidação de protocolos sanitários rigorosos são necessários (Fuentes *et al.*, 2020). Monitorar a saúde do rebanho impede a contaminação de animais produtivos por animais improdutivos, aumenta a eficiência de detecção precoce de doenças e eleva a eficácia das intervenções veterinárias (Masello *et al.*, 2021). Além disso, o custo de se manter a qualidade das operações é reduzido em relação ao custo associado a perdas, retrabalho, e problemas de qualidade (Rasmussen *et al.*, 2021).

Associado a estes fatores há a inserção de tecnologias de produção que automatizam etapas importantes de manejo dos animais (Masello *et al.*, 2021). A alimentação, monitoramento da saúde e ordenha são alguns dos processos que tem alta receptividade quanto a introdução de tecnologias na pecuária leiteira (Romaniuk *et al.*, 2021). A qualidade de produção também é impactada com a utilização de tecnologias, uma vez que os protocolos de manejo são seguidos com maior rigor (Dutton-Regester *et al.*, 2020). Destaca-se aqui o aumento da qualidade percebida do leite com o emprego destas tecnologias. No entanto, trata-se de um fator gerador de altos custos para as propriedades e que em alguns casos se torna inviável para os produtores (Fuentes *et al.*, 2020).

O monitoramento da eficiência do processo de ordenha pode ser realizado a partir do controle dos custos com materiais e manutenção de ordenha (Edwards *et al.*, 2020). A inspeção e limpeza destes equipamentos deve ser periódica a fim de evitar a contaminação do leite produzido. Ressalta-se a importância dos protocolos de higiene a serem observados na rotina de manejo dos animais (Romaniuk *et al.*, 2021). Esta prática contribui para a redução da taxa de incidência de mastites, problemas reprodutivos, entre outras doenças (Masello *et al.*, 2021). Com base nestas informações, os produtores podem otimizar o processo de ordenha a fim de se obter uma produção consistente, evitando sazonalidade de volume e qualidade do leite (Edwards *et al.*, 2020).

Os aspectos econômicos também configuram impactos na produção do leite. Isso se deve a variações no preço do leite e dos custos dos insumos de produção (Rasmussen *et al.*, 2021). A relação de troca entre estes é afetada quando o custo unitário se torna maior que o preço por litro, estimulando a diminuição da produção (Godfrey, Ip e Nordblom, 2022). Além disso, o acesso reduzido a mercados põe em risco a permanência de pequenos produtores na atividade. O preço pago ao produtor corresponde a uma métrica de valor para a tomada de

decisão de produtores (Rasmussen *et al.*, 2021). Existem programas de incentivo para que produtores invistam em maior qualidade em suas propriedades a fim de obter melhores preços pelo leite produzido. No entanto, na prática, observa-se que em alguns casos não há esse retorno de investimento na qualidade, o que desestimula os produtores a buscarem melhorias reais em suas propriedades (Rasmussen *et al.*, 2021).

A quantidade de leite vendido trata-se de um indicador útil para a avaliação dos sistemas de qualidade, marketing e distribuição nas propriedades (Maina *et al.*, 2020). Isso porque o leite ao apresentar os requisitos necessários de qualidade amplia suas possibilidades de comercialização (Okello; Luttah, 2022). Além disso, monitorar a quantidade de leite vendido pode auxiliar produtores a identificarem as tendências de demanda existentes, promovendo ajustes na produção e boas práticas de armazenamento, venda e logística (Vanhuysse; Bailey; Tranter, 2021).

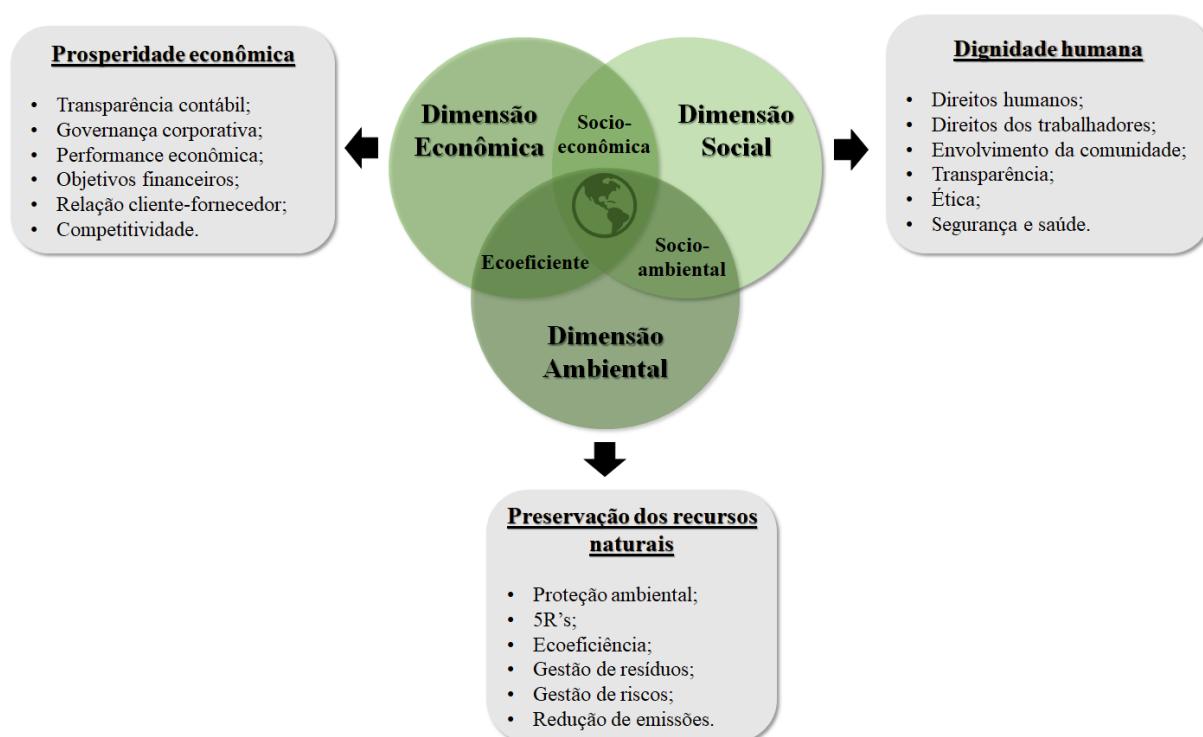
A receita do leite contempla um dos principais indicadores financeiros da pecuária leiteira, pois fornece subsídios de avaliação da viabilidade econômica e da lucratividade da produção (Maina *et al.*, 2020). Logo, entender as causas de variação da receita é uma informação importante para que os produtores tomem decisões sobre investimentos, melhorias operacionais e novas estratégias de atuação (Okello; Luttah, 2022). Nesse sentido as operações na pecuária leiteira se tornam mais seguras e orientadas, impactando na saúde financeira das propriedades e sustentabilidade de produtores no setor (Vanhuysse; Bailey; Tranter, 2021).

No plano econômico de produção do leite há ainda os indicadores de Custo Operacional Efetivo (COE), Custo Operacional Total (COT) e Custo Total (CT). O COE contempla todos os itens de custos variáveis ou diretos como insumos, combustível, manutenção, mão de obra, serviços terceirizados, transporte, entre outros (CEPEA, 2024). Já o COT representa a soma do COE e da parcela dos custos indiretos relacionada a depreciação de máquinas, taxas de produção, implementos, entre outros (CEPEA, 2024). Por fim, o CT corresponde a soma do COT e do custo de oportunidade do uso de capital e da terra (CEPEA, 2024). Na pecuária leiteira, o COE permite um acompanhamento dos custos diretamente associados a produção do leite, incluindo despesas com alimentação, saúde dos animais, mão de obra, equipamentos e insumos. O monitoramento deste indicador é essencial para a identificação de centros de custos que podem ser reduzidos sem promover a perda de qualidade e/ou produtividade (CEPEA, 2024).

Cabe lembrar que a sustentabilidade é um fator importante a ser considerado na produção do leite. Avanços na pecuária de baixo carbono tem sido realizados, bem como a inserção de energias renováveis na produção, otimização do consumo de recursos, tratamento

adequado de resíduos e redução de emissões (Soteriades *et al.*, 2020). A utilização de certificações neste aspecto pode ajudar na identificação de propriedades sustentáveis e agregar valor ao produto (Jebari *et al.*, 2022). A combinação de práticas sustentáveis na pecuária leiteira pode auxiliar na redução de custos de produção, redução do impacto ambiental e na formação de sistemas agropecuários mais resilientes no longo prazo (Leitgeb *et al.*, 2023). A Figura 2 representa o tripé de sustentabilidade que abrange as dimensões econômica-social-ambiental, e que pode ser incorporado a cadeia produtiva do leite.

Figura 2 – Tripé de sustentabilidade



Fonte: Do autor (2024)

A dimensão econômica se refere a capacidade de promover um ambiente organizacional rentável a longo prazo enquanto avanços no plano sustentável são obtidos (Leitgeb *et al.*, 2023). Neste sentido, aspectos de gestão de desempenho como transparência contábil das operações, governança corporativa, performance econômica, objetivos financeiros, relação cliente-fornecedor e competitividade devem ser ressaltados para o alcance de melhores resultados (Arvidsson Segerkvist *et al.*, 2020). Na pecuária leiteira a sustentabilidade econômica envolve boas práticas que garantam a viabilidade financeira a longo prazo, a partir da otimização do uso de recursos, adoção de tecnologias que aumentam a produtividade e reduzam de custos, e diversificação de fontes de receita, certificações de qualidade (Maina *et al.*, 2020). A

valorização de subprodutos do leite através de certificações de qualidade garantem aos produtores o acesso a mercados mais rentáveis (Talukder *et al.*, 2021).

A dimensão social trata da criação de um ambiente de trabalho inclusivo e justo, de modo que os direitos dos trabalhadores sejam garantidos e haja a redução de desigualdades (Arvidsson Segerkvist *et al.*, 2020). Questões relacionadas aos direitos humanos, integração comunitária, transparência, ética, segurança e saúde podem ser trabalhadas nesse sentido (Arvidsson Segerkvist *et al.*, 2020). A sustentabilidade social na pecuária leiteira dedica-se ao alcance do bem-estar dos trabalhadores e das comunidades locais (Feyissa *et al.*, 2023). Para tanto, criar condições de trabalho seguras através de capacitações contínuas destes colaboradores é importante. Isso porque as equipes de trabalho se tornam mais motivadas e aumenta a capacidade de retenção de talentos nas propriedades (Arvidsson Segerkvist *et al.*, 2020). Projetos de cunho social que objetivam a disseminação da responsabilidade social corporativa também contribuem para o fortalecimento da relação com as comunidades (Feil *et al.*, 2023).

A dimensão ambiental opera no sentido de reduzir o impacto negativo das operações de produção no meio ambiente (Arvidsson Segerkvist *et al.*, 2020). Nessa perspectiva, a proteção ambiental, 5R's (reduzir, reutilizar ou reaproveitar, reciclar, repensar e recusar), ecoeficiência, gestão de resíduos, gestão de riscos e redução de emissões contemplam aspectos importantes que fazem parte das ações criadas nesta dimensão (Jebari *et al.*, 2022). Na cadeia produtiva do leite a sustentabilidade ambiental ocorre através de uma gestão eficiente de resíduos a partir da produção de fertilizantes, biogás, ou com a adoção de práticas de pastoreio rotativo, evitando a degradação do solo (Arvidsson Segerkvist *et al.*, 2020). A utilização de energias renováveis, práticas de manejo que promovam menor emissão de gases de efeito estufa bem como técnicas inovadoras de irrigação que viabilizem a conservação de nascentes também podem ser implementadas para este fim (Jebari *et al.*, 2022). Vale ressaltar a importância de criação de regulações e incentivos para a preservação da biodiversidade local nas propriedades (Arvidsson Segerkvist *et al.*, 2020).

Em suma, a gestão de desempenho da pecuária leiteira avança no sentido de promover maior sustentabilidade e eficiência para o setor (Soteriades *et al.*, 2020). Com base em técnicas de apoio a tomada de decisão, modelos de gestão e monitoramento os produtores adquirem subsídios para avançar na atividade em relação a produtividade, qualidade e redução de custos (Pedolin *et al.*, 2021). Logo, ações voltadas para a promoção de bem-estar, saúde animal e preservação do meio ambiente estão entre os pilares da pecuária leiteira moderna (Froldi *et al.*, 2022).

Estudos têm avançado na busca de uma pecuária leiteira mais sustentável. Pedolin *et al.* (2021) em sua análise de gestão de desempenho calcularam pontuações de eficiência ambiental para oito grupos de produtos (leite, gado, porcos, cereais, beterraba, batata, legumes e frutas) na Suíça. Soteriades *et al.* (2020) desenvolveram um indicador de ecoeficiência para cada uma das 738 fazendas leiteiras do Reino Unido que agrega múltiplas cargas e as expressa por unidade de leite e carne bovina produzida. Já Barros *et al.* (2022) forneceram uma Análise do Ciclo de Vida (ACV) dos sistemas de produção de leite de vaca cru dos dois estados mais representativos (Paraná e Minas Gerais) para a produção de leite no Brasil, e avançaram em sua análise de desempenho ambiental do leite produzido no Brasil (na porta da fazenda) com o do leite produzido em outras partes do mundo.

Froldi *et al.* (2022) realizaram uma ACV em 55 explorações leiteiras localizadas no norte da Itália para investigar o impacto ambiental da produção do leite. Cortés *et al.* (2021) promoveram uma análise dos níveis de ecoeficiência de mais de 100 propriedades da zona Galega. Já Ji *et al.* (2020) estudaram a relação dos níveis térmicos na produtividade de vacas leiteiras em uma região de clima subtropical. Sefeedpari, Shokoohi e Pishgar-Komleh (2020) discutem em seu estudo a eficiência técnica como um indicador-chave do uso de energia nos sistemas de produção leiteira. Por fim, Zhang *et al.* (2020) realizaram uma análise de desempenho para a gestão de resíduos sólidos em propriedades leiteiras da China.

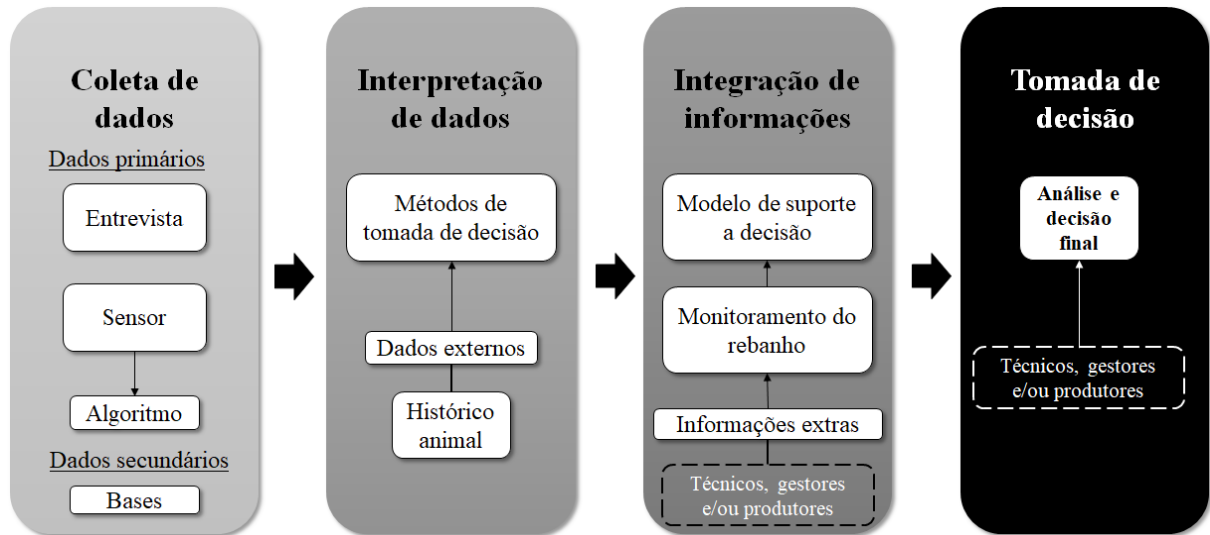
2.2 Métodos de tomada de decisão aplicados a produção de leite

A pecuária leiteira contempla uma rede de fatores interrelacionados que fornecem informações consistentes para uma tomada de decisão orientada e eficiente (Cabrera *et al.*, 2020). A tomada de decisão na pecuária leiteira pode ocorrer com o apoio de indicadores e modelos de suporte que favorecem a identificação de soluções eficazes para o atingimento de metas pré-estabelecidas (De Lauwere *et al.*, 2020). Ressalta-se a contribuição destes modelos quanto a simplificação das análises, reduzindo o consumo de recursos envolvidos no processo (De Lauwere *et al.*, 2020).

A tecnologia envolvida no processo de tomada de decisão agrega agilidade às operações, coletando dados de forma rápida e precisa (Baldin *et al.*, 2021). A pecuária de precisão surge nesse instante, representando uma abordagem inovadora de gestão dos rebanhos para otimização da produção e saúde dos animais (De Lauwere *et al.*, 2020). A utilização de sensores garante a coleta instantânea de informações críticas relacionadas a nutrição, saúde, comportamento e produção de leite dos animais (Oehm *et al.*, 2023). Dessa forma, é viabilizada

a intervenção rápida para melhoria das operações e alcance de maior eficiência dos modelos de decisão (Baldin *et al.*, 2021). A Figura 3 representa o diagrama de fluxo para a tomada de decisão na pecuária leiteira.

Figura 3 – Diagrama de fluxo para tomada de decisão na pecuária leiteira



Fonte: Do autor (2024)

De acordo com a Figura 3, a tomada de decisão é antecedida por outras etapas importantes como a coleta e interpretação de dados, e a integração de informações. A coleta de dados pode ser favorecida pelo apoio de tecnologias atuais como o uso de sensores e dispositivos IoT, que tornam esta etapa mais rápida, integrada e precisa (Oehm *et al.*, 2023). No entanto, trata-se de uma medida economicamente inviável para alguns pequenos e médios produtores, sendo necessária a ação de técnicos especializados para o cumprimento desta etapa (Froldi *et al.* 2022).

A etapa de interpretação dos dados ocorre mediante o apoio dos métodos de tomada de decisão que serão utilizados para a compilação dos dados. Informações sobre a rotina e histórico dos animais são importantes para a complementação dos modelos de decisão (Cabrera; Fadul-Pacheco, 2021). Nesta etapa há a formalização de um status de operação, que se refere a observações relacionadas às práticas de manejo (Froldi *et al.* 2022). Isso permite a separação do rebanho em diferentes lotes de animais, por exemplo, animais eficientes e ineficientes, doentes e saudáveis (Ndambi *et al.*, 2020).

A próxima etapa corresponde a integração de informações relacionadas a produção do leite. Trata-se de uma etapa importante para a otimização da gestão e tomada de decisão no setor (Cabrera *et al.*, 2020). Isso porque ao validar dados de diferentes fontes como sistemas de

controle de saúde dos animais, níveis de produção, análise de qualidade do leite e finanças, os produtores, técnicos e/ou gestores podem obter uma visão mais completa de suas operações (Ndambi *et al.*, 2020). Esta integração também contribui para a gestão do conhecimento nas propriedades, havendo o compartilhamento de experiências e a colaboração entre agentes do processo (Cabrera *et al.*, 2020).

Por fim, a última etapa contempla a tomada de decisão que deve ser orientada com base em todas as informações obtidas até o momento por produtores, técnicos e/ou gestores (Baldin *et al.*, 2021). Acentua-se aqui a importância do desenvolvimento de ferramentas adequadas de visualização de dados que promovam uma interação homem-máquina de forma fluida e dinâmica, a fim de potencializar os resultados desta etapa (Wankar; Rindhe; Doijad, 2021). No entanto, considerando que este setor aborda uma multiplicidade de indicadores e que os níveis dos sistemas de produção do leite são altamente integrados, as tomadas de decisão devem ser realizadas cuidadosamente, já que um erro cometido em um nível do sistema pode afetar os demais (Froldi *et al.* 2022).

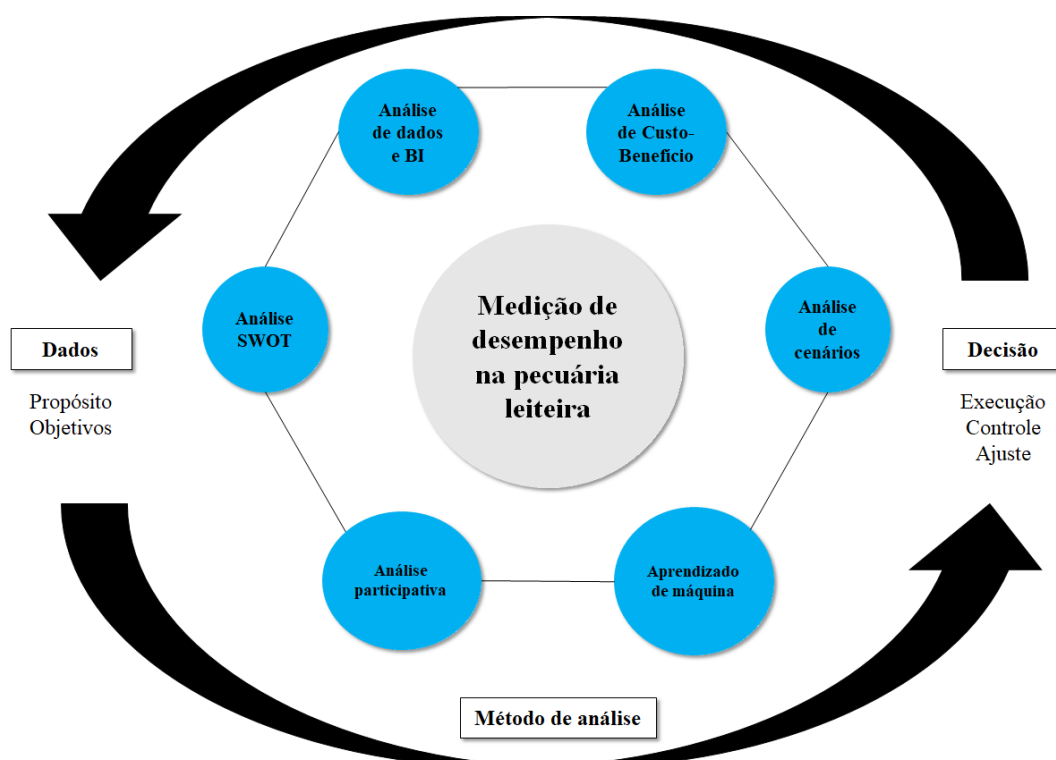
Os métodos de tomada de decisão configuram fontes seguras para a análise de dados e geração de resultados fundamentados no âmbito da pecuária leiteira (Baldin *et al.*, 2021). No entanto, cabe ao proprietário e/ou gestor a escolha do método de apoio que mais se adequa ao contexto da propriedade (Feil *et al.*, 2023). A tomada de decisão muitas vezes incorre em custos adicionais no processo, a partir da implantação de tecnologias, capacitação de colaboradores e manutenção de equipamentos por exemplo, o que pode dificultar a gestão de pequenos e médios produtores (Froldi *et al.* 2022). Considerando a existência de diferentes metodologias de apoio a tomada de decisão, a Figura 4 representa um esboço dos principais métodos adotados no contexto da pecuária leiteira.

Figura 4 – Métodos de tomada de decisão na produção de leite

(Continua)

Figura 4 - Métodos de tomada de decisão na produção de leite

(Conclusão)



Fonte: Do autor (2024)

A Figura 4, pode ser interpretada em três fases, Dados, Método de análise e Decisão. Após a definição clara do propósito e objetivos de análise, ocorre a coleta de dados. Logo, procede-se a definição do método de análise. No âmbito da pecuária leiteira destaca-se algumas metodologias como a Análise de dados e ferramentas de Business Intelligence (BI), a Análise de custo-benefício, Análise SWOT, Análise de cenários, Análise participativa e técnicas de Aprendizado de máquina (Keceli *et al.*, 2020; Juliansyah; Sulistyowati; Badrudin, 2022; Jackson *et al.*, 2022). Com estes métodos de apoio, busca-se a concretização da tomada de decisão, com a execução, controle e ajuste de operações do processo de produção do leite (Froldi *et al.* 2022).

A análise de dados na produção do leite é necessária para a melhoria da eficiência e produtividade nas operações (Krishna *et al.*, 2021). Um aspecto importante contempla a identificação de padrões e tendências nos dados, permitindo a ação antecipada de proprietários e/ou gestores quanto a detecção de doenças, ajustes na alimentação e implementação de boas práticas de manejo (Baldin *et al.*, 2021). A previsão de demanda e gestão eficiente de recursos

também são resultados positivos alcançados pela análise de dados neste contexto (Krishna *et al.*, 2021).

O emprego da análise de dados e ferramentas de BI permite uma análise mais clara e integrada das informações de produção, a partir da conversão de dados brutos em dados acionáveis (Baldin *et al.*, 2021; Schuetz.; Schrefl, 2023). Informações externas como dados climáticos e econômicos de mercado podem ser incorporados a painéis promovendo a criação de um pacote orientado de tomada de decisão (Schuetz.; Schrefl, 2023). Esta análise ainda auxilia no alcance da sustentabilidade econômica e ambiental das operações, viabilizando a resposta rápida de produtores às demandas de mercado e mudanças no clima (Soteriades *et al.*, 2020). A implementação deste padrão de análise nas propriedades requer investimentos em infraestrutura de dados, capacitação de colaboradores, e um esforço contínuo na criação e manutenção de uma cultura de tomada de decisão baseada em dados (Baldin *et al.*, 2021).

No que se refere a análise de custo-benefício, trata-se de uma metodologia ampla e que permite aos produtores avaliarem os custos de tomada de decisões em diferentes operações na propriedade, seja na compra de equipamentos, ajustes na nutrição dos animais, ou implementação de tecnologias (Maina *et al.*, 2020). Por exemplo, a decisão de investir em um sistema de ordenha automatizado pode ser orientada por uma análise de custo-benefício. Logo, os custos incluem a compra do equipamento, instalação, manutenção e treinamento de colaboradores. Já os benefícios estão associados a redução de mão de obra, aumento de eficiência da operação, melhoria da qualidade do leite e redução de estresse do rebanho. Cabe lembrar a consideração do horizonte temporal de análise em que os custos e benefícios serão avaliados (Edwards *et al.*, 2020). Isso permite com que produtores possam avaliar o retorno sobre o investimento realizado (Maina *et al.*, 2020).

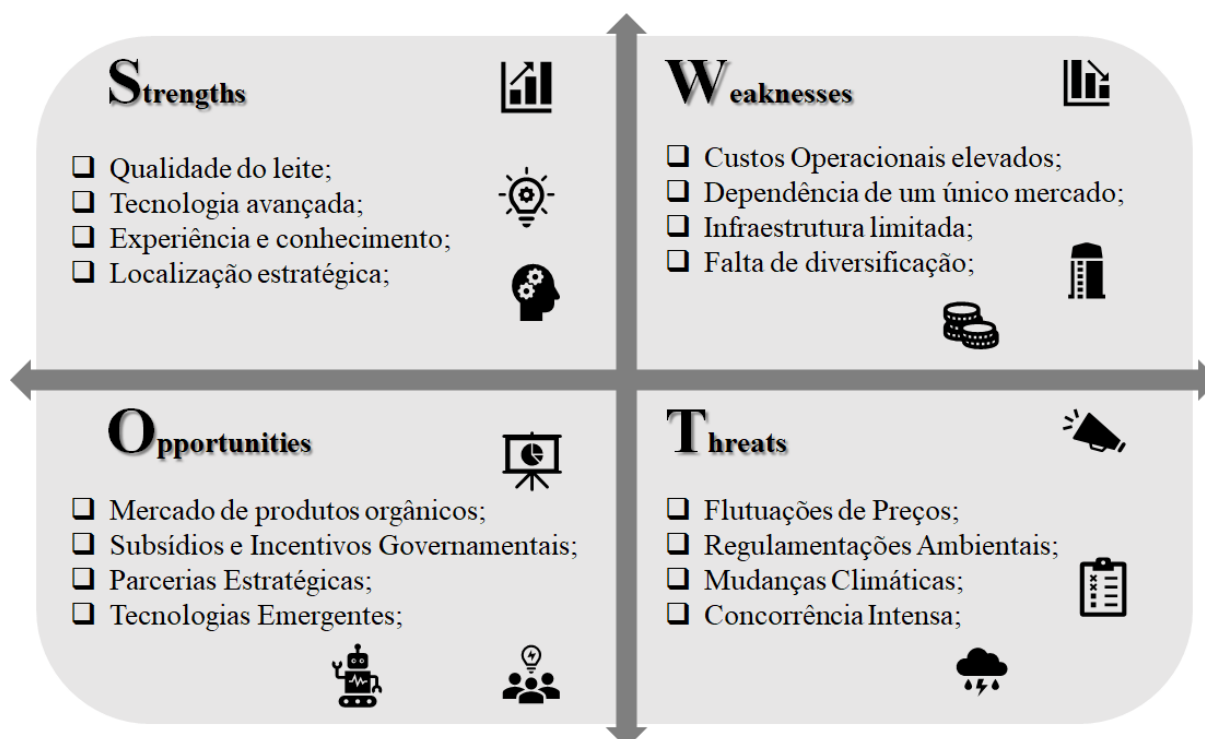
A utilização da análise SWOT (*Strengths, Weaknesses, Opportunities, Threats*) como metodologia de apoio a tomada de decisão na pecuária leiteira também é uma prática observada (Verraes *et al.*, 2015). Com base nesta análise é possível a identificação de pontos internos à propriedade, forças e fraquezas, e pontos externos, oportunidades e ameaças (Verraes *et al.*, 2015). Nesse sentido, os produtores pode atuar estrategicamente para alavancar suas vantagens competitivas e reduzir os riscos de operação (Verraes *et al.*, 2015). A Figura 5 contempla um exemplo de aplicação da Análise SWOT no âmbito da pecuária leiteira.

Figura 5 - Exemplo prático da análise SWOT na pecuária leiteira

(Continua)

Figura 5 - Exemplo prático da análise *SWOT* na pecuária leiteira

(Conclusão)



Fonte: Do autor (2024)

Na pecuária leiteira as forças (*Strengths*) podem ser entendidas como atributos internos às propriedades que as tornam diferentes de seus concorrentes no mercado, proporcionando vantagem competitiva (Juliansyah; Sulistyowati; Badrudin, 2022). Produtores e/ou gestores que conhecem as forças de sua propriedade têm condições de fortalecer o seu posicionamento de mercado frente as oportunidades do ambiente externo (Feil *et al.*, 2023). Nesse sentido, aspectos relacionados a qualidade do leite, tecnologia avançada, experiência e conhecimento, e localização estratégica constituem alguns exemplos de forças internas para as propriedades (Juliansyah; Sulistyowati; Badrudin, 2022). Tais forças reiteram a importância de investimentos em programas de saúde animal e manejo bem como no treinamento de colaboradores para alavancagem de resultados (Verraes *et al.*, 2015).

Ainda no ambiente interno das propriedades podem ser identificadas as fraquezas (*Weaknesses*) que constituem atributos negativos que podem limitar o desempenho das operações no contexto da produção do leite (Juliansyah; Sulistyowati; Badrudin, 2022). Logo, aspectos relacionados a custos operacionais elevados, dependência de um único mercado, infraestrutura limitada e falta de diversificação contemplam alguns exemplos destes atributos (Maina *et al.*, 2020). Assim, considera-se importante o papel dos gestores e/ou produtores para

a negociação de melhores condições de compra, diversificação da base de clientes, planejamento de investimentos em infraestrutura e desenvolvimento de novos produtos, como alternativas de contorno para estes fatores de vulnerabilidade (Maina *et al.*, 2020).

Neste contexto de produção de leite as oportunidades (*Opportunities*) podem ser compreendidas como fatores positivos externos às propriedades que favorecem o crescimento, inovação e melhoria de desempenho (Juliansyah; Sulistyowati; Badrudin, 2022). A tendência de crescimento do mercado de produtos orgânicos, a possibilidade de aquisição de subsídios e incentivos governamentais, a realização de parcerias e beneficiamento da produção por tecnologias emergentes correspondem a exemplos de oportunidades (Cabrera; Fadul-Pacheco, 2021). Cabe aos produtores identificarem estas oportunidades e inseri-las no planejamento estratégico de gestão de desempenho de suas propriedades, a fim de expandir o market share e a qualidade de oferta de produtos (Verraes *et al.*, 2015).

As ameaças (*Threats*) configuram fatores negativos externos às propriedades leiteiras que podem impor desafios e dificuldades para o alcance de melhor desempenho e sustentabilidade econômica, ambiental e social (Juliansyah; Sulistyowati; Badrudin, 2022). Aspectos relacionados a flutuações de preços, regulamentações ambientais, mudanças climáticas e concorrência intensa podem ser listados como exemplos de ameaças externas (Juliansyah; Sulistyowati; Badrudin, 2022). A identificação ágil de ameaças permite que produtores possam atualizar suas estratégias de atuação mitigando riscos e projetando seus ativos para enfrentamento de possíveis turbulências de mercado (Verraes *et al.*, 2015).

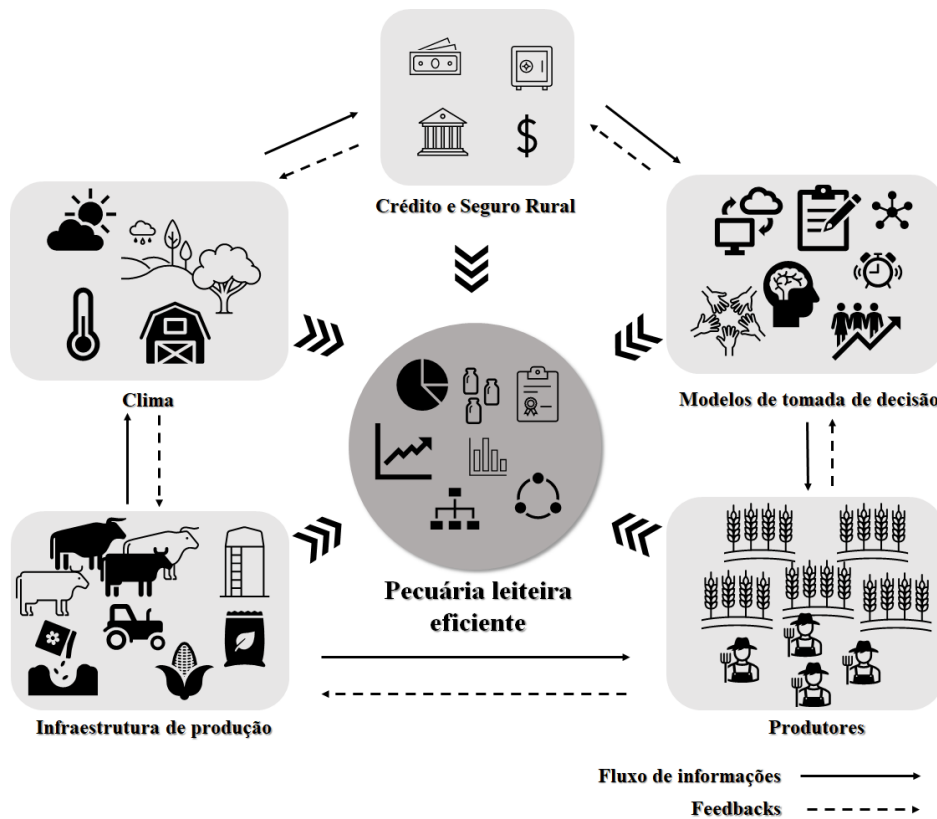
A tomada de decisão orientada pela análise participativa na pecuária leiteira contempla um modelo de gestão em que todas as partes interessadas contribuem de forma efetiva nos processos de melhoria das operações (De Lauwere *et al.*, 2020). Desta forma, produtores e/ou gestores e demais colaboradores operam de forma conjunta para o aumento da eficiência operacional (Feil *et al.*, 2023). Além disso, este modelo promove a inclusão, fortalece o compromisso de stakeholders e favorece o desenvolvimento de novas tecnologias (Siafakas *et al.*, 2019). Nesse sentido, abordar a análise participativa requer, a priori, de um entendimento da estrutura de produção no contexto da pecuária leiteira (De Lauwere *et al.*, 2020). A Figura 6 corresponde a um esboço desta estrutura.

Figura 6 - Estrutura da pecuária leiteira

(Continua)

Figura 6 - Estrutura da pecuária leiteira

(Conclusão)



Fonte: Do Autor (2024)

Nota-se que os modelos de tomada de decisão contribuem para o processo de gestão eficiente da pecuária leiteira, todavia, representam apenas um dos aspectos de influência para o setor (Holly *et al.*, 2019). A gestão participativa se insere nesta estrutura como um dos elementos disponíveis para a tomada de decisão na pecuária leiteira (De Lauwere *et al.*, 2020). Neste sentido, a estrutura apresentada ressalta a interdependência de cinco pilares da pecuária de leite eficiente, a saber, clima, infraestrutura de produção, crédito e seguro rural, produtores e/ou gestores, e modelos de tomada de decisão (Siafakas *et al.*, 2019). A representação dos fluxos de informação e feedbacks destacam a importância da comunicação entre as operações do setor bem como a capacidade de adaptação do sistema frente as oportunidades e ameaças externas (Feil *et al.*, 2023).

A análise de cenários também corresponde a uma metodologia de apoio a tomada de decisão na pecuária leiteira (Jackson *et al.*, 2022). Trata-se de uma análise que permite a combinação de diferentes indicadores ou variáveis aleatórias que simulam situações de ocorrência futura (Salinas-Martínez *et al.*, 2020). Tais indicadores podem envolver questões

climáticas, flutuações de preços de insumos e produtos, e até diferentes níveis de demanda de clientes. Com base na análise de cenários, os produtores podem se antecipar quanto a formalização de planos de contingência, pautados em cenários pessimistas e realistas. Este tipo de análise promove a redução de riscos na tomada de decisão e aumenta a resiliência nas operações de produção nas propriedades (Salinas-Martínez *et al.*, 2020). Assim, destaca-se a utilização da técnica de Simulação de Monte Carlo para a análise de cenários (Lau *et al.*, 2022).

No âmbito da avaliação de cenários, estudos tem sido desenvolvidos para a busca de maior eficiência na pecuária leiteira. Por exemplo, Rasmussen *et al.* (2021) utilizaram a simulação de cenários para estimar as perdas anuais por vaca em rebanhos infectados por doenças e as perdas regionais totais. Já Godfrey, Ip e Nordblom (2022) forneceram análises comparativas de risco de três regiões leiteiras da Austrália. Masello *et al.* (2021) avaliaram o efeito de programas de manejo reprodutivo na economia de novilhas leiteiras de reposição a partir da geração de cenários.

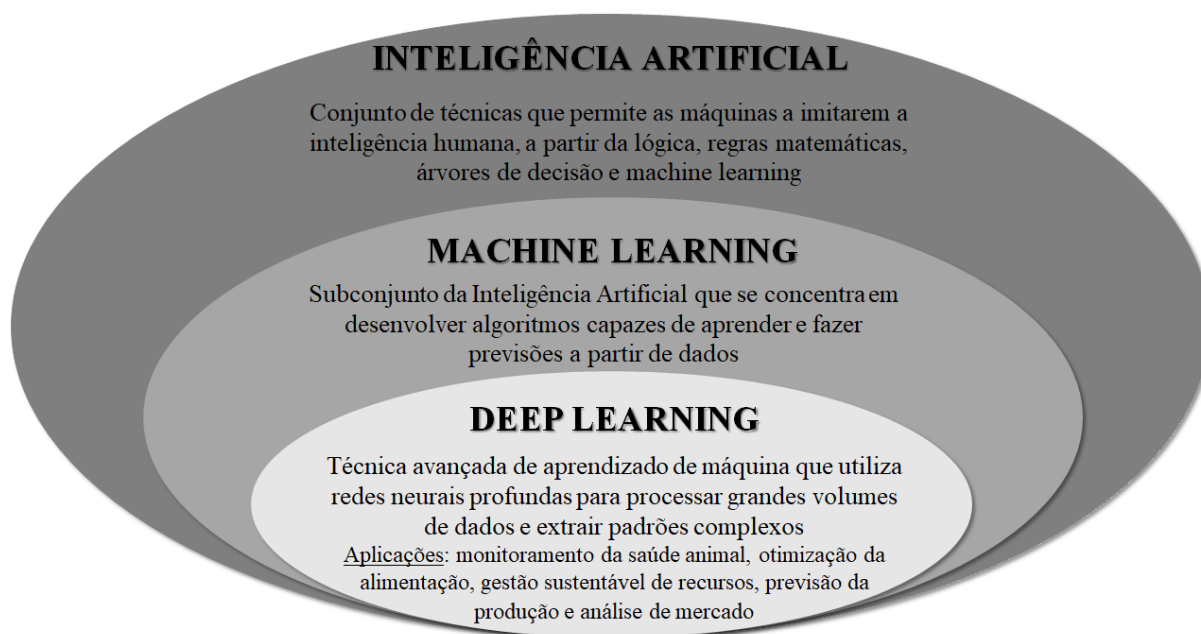
Por fim, o aprendizado de máquina constitui uma das metodologias de apoio a tomada de decisão no âmbito da produção do leite (Naqvi *et al.*, 2022). O aprendizado de máquina trata-se de uma área consolidada no campo da inteligência artificial e que contempla a criação de algoritmos capazes de aprender com os dados fornecidos, fazer previsões e tomar decisões autônomas (Naqvi *et al.*, 2022). No contexto da pecuária leiteira o aprendizado de máquina tem revolucionado o padrão de gestão de desempenho nas propriedades com melhorias perceptíveis na produtividade, saúde dos animais e sustentabilidade das operações (Keceli *et al.*, 2020). A Figura 7 representa um esquema da hierarquia de aprendizado no contexto da pecuária leiteira.

Figura 7 - Hierarquia de aprendizado na pecuária leiteira

(Continua)

Figura 7 - Hierarquia de aprendizado na pecuária leiteira

(Conclusão)



Fonte: Do autor (2024)

A adoção de técnicas de aprendizado de máquina na pecuária leiteira contribui para o setor na medida em que produtores tomam decisões de forma rápida e precisa, a partir de insights orientados e eficientes (Oehm *et al.*, 2023). A integração de tecnologias avançadas nas operações de produção do leite transformam este ambiente, promovendo ganhos de produtividade e saúde animal (Keceli *et al.*, 2020). Nesse sentido, algoritmos de machine learning podem ser projetados para a identificação de padrões, garantindo a detecção precoce de doenças, infecções ou estresse nos animais (Tian *et al.*, 2023).

O deep learning, como técnica de aprendizado profundo, realiza o processamento de grandes volumes de dados e extrai destes padrões complexos que contribuem para a gestão de desempenho das propriedades leiteiras (Silva, 2016). A partir de redes neurais artificiais se torna possível o reconhecimento de imagens dos animais, viabilizando o seu monitoramento diário (Braga; Ludermir; Carvalho, 2000; Tian *et al.*, 2023). Também podem auxiliar na atualização da dieta dos animais mediante o processamento de informações do clima, níveis de produção do leite e consumo de alimentos (Zheng *et al.*, 2023). A gestão sustentável de recursos também pode ser beneficiada neste sentido, com a previsão da demanda dos animais por alimentos e água, otimizando o consumo de recursos e reduzindo desperdícios (Arvidsson Segerkvist *et al.*, 2020).

Por fim, cabe lembrar alguns estudos que tem sido desenvolvidos com base na utilização de redes de aprendizado profundo na pecuária leiteira (Zheng *et al.*, 2023). Por exemplo, Tassinari *et al.* (2021) desenvolveram uma rede neural para o reconhecimento em tempo real de vacas individuais, detectando suas posições, ações e movimentos e registrando os resultados do histórico temporal de cada animal. Já Keceli *et al.* (2020) desenvolveram uma abordagem automatizada baseada em algoritmos de aprendizado de máquina e diversos comportamentos de bovinos para prever o tempo de parto de bovinos em fazendas leiteiras. Liseune *et al.* (2021) proporam uma nova metodologia para prever toda a curva de lactação de vacas leiteiras.

2.3 Contextualização da produção de leite

A produção de leite tem forte participação na economia global, contribuindo satisfatoriamente para a renda de muitas famílias e o desenvolvimento rural (Arvidsson Segerkvist *et al.*, 2020). Em muitos países destaca-se a participação da pecuária leiteira no Produto Interno Bruto (PIB) (Maina *et al.* 2020). A formação de uma cadeia de valor que se inicia com a produção do leite nas propriedades e se estende a comercialização do leite e seus derivados contempla grande parte da população mundial (Arvidsson Segerkvist *et al.*, 2020). Este alto consumo promove a expansão da demanda e movimentam a economia global a partir da interação de setores diversos como processamento, logística e varejo (Cabrera; Fadul-Pacheco, 2021).

A geração de empregos diretos e indiretos é um aspecto positivo associado a cadeia de produção do leite (Beber; Lakner; Skevas, 2021). Isso porque a produção de lácteos envolve uma sequência lógica de processos que exigem mão de obra em diferentes níveis de qualificação. Observa-se também a contribuição deste setor para o amparo de famílias em situação de vulnerabilidade econômica, pois a produção do leite confere uma fonte de renda estável e necessária nestes casos para a sobrevivência destas pessoas (Silveira *et al.*, 2022). Logo, a produção do leite contribui para a redução de práticas de êxodo rural e induz o fortalecimento de indústrias relacionadas ao setor como fabricantes de produtos e equipamentos agropecuários, medicamentos de uso veterinário, insumos agropecuários, entre outros (Arvidsson Segerkvist *et al.*, 2020).

A produção do leite contribui estrategicamente para a segurança alimentar de muitos países (Givens *et al.*, 2020). Por se tratar de um alimento rico em nutrientes essenciais para a população, em especial, para a dieta de crianças e idosos, justifica-se o incentivo de fortalecimento do setor em diferentes regiões do mundo (Givens *et al.*, 2020). A realização de

incentivos de produção para todas as classes de produtores é importante, pois contribui para a autonomia alimentar do país. Logo, um país que apresenta uma produção local consolidada, garante o atendimento da demanda interna e ainda consegue obter vantagem competitiva global, exportando os níveis de produção excedentes e ampliando suas fontes de receita (Maina *et al.*, 2020).

A pecuária leiteira ainda promove incentivos para o desenvolvimento de tecnologias dedicadas a melhoria da eficiência e produtividade na produção de leite e derivados (Kovács; Szűcs, 2020). A melhoria da eficiência reflete positivamente na economia, permitindo que os recursos financeiros obtidos sejam reinvestidos, criando um ciclo virtuoso para a economia dos países (Kovács; Szűcs, 2020). Alguns avanços têm sido alcançados com base no desenvolvimento de tecnologias de manejo animal e melhoria da genética de animais (Masello *et al.*, 2021). Também se considera a tendência por uma produção mais sustentável, com a emissão de menores índices de gases de efeito estufa, reutilização de resíduos do processo de produção, e economia de água por exemplo (Zanin *et al.*, 2020).

A criação de programas e políticas de apoio a produção do leite são vitais para a melhoria do setor (MAPA, 2024). Isso porque medidas relacionadas a implementação de incentivos fiscais, planos de crédito e financiamento, e assistência técnica especializada podem ser subsidiadas por estes programas (MAPA, 2024). Trata-se de medidas importantes para a proteção de produtores contra as volatilidades do mercado e clima, especialmente daqueles produtores mais vulneráveis economicamente (Feil *et al.*, 2023). A implementação destas políticas de apoio permitem ainda o investimento infraestrutural das propriedades e, conseqüentemente, o desenvolvimento da comunidade local (Feyissa *et al.*, 2023).

No Brasil, alguns programas podem ser ressaltados no âmbito da gestão, qualidade e infraestrutura. Programas de gestão, qualidade e infraestrutura como o “Programa leite mais saudável” e o “Plano Nacional de Melhoria da Qualidade do Leite (PNQL)” representam iniciativas para o avanço da eficiência da pecuária leiteira no país (MAPA, 2024). Se tratando do acompanhamentos dos preços do leite, iniciativas como o “Conseleite” e “Política de Garantia de Preços Mínimos (PGPM)” representam instrumentos balizadores para uma melhor performance de pequenos e médios produtores no Brasil (MAPA, 2024). O Conseleite foi desenvolvido mediante o interesse em se estabelecer um valor de referência para o preço do leite comercializado entre produtores e indústrias. Já o PGPM promove uma maior estabilidade reduzindo oscilações na renda dos produtores e garantindo uma remuneração mínima e a regularidade do abastecimento local (MAPA, 2024).

Do ponto de vista social, a produção de leite auxilia no desenvolvimento das comunidades locais (Arvidsson Segerkvist *et al.*, 2020). A pecuária leiteira em muitas regiões corresponde a uma atividade familiar, pautada no seguimento de tradições entre gerações (Barros *et al.*, 2022). Logo, a produção de leite permite a subsistência das famílias e a maior integração populacional entre comunidades (Barros *et al.*, 2022). O consumo do leite permite o acesso da população a nutrientes essenciais para a garantia de saúde e bem-estar das pessoas. Destaca-se aqui as contribuições da cadeia produtiva do leite no âmbito da redução dos índices de desnutrição e melhoria da saúde pública (Givens *et al.*, 2020).

Pautas de inclusão social e empoderamento das mulheres também tem avançado como benefícios obtidos pela prática da pecuária leiteira (Sivasubramanian; Adarsh; Krishnamurthy, 2024). Em muitas propriedades as mulheres desempenham funções importantes sejam em atividades estratégicas na gestão da produção, ou em atividades de cunho operacional, na condução dos processos de ordenha, alimentação e cuidados dos animais (Nath, 2022). Trata-se de uma tendência observada nas propriedades que possibilita a complementação da renda familiar, a redução da desigualdade de gêneros e fortalecimento do seu papel nas decisões familiares e na comunidade (Sivasubramanian; Adarsh; Krishnamurthy, 2024).

No que se refere a práticas de coesão social, a formação de cooperativas de produtores é uma alternativa que confere sustentabilidade e eficiência da produção (Feil *et al.*, 2023). Neste sentido, pequenos produtores podem se beneficiar com o compartilhamento de experiências e recursos, conseguindo acesso a melhores preços para sua produção (Feyissa *et al.*, 2023). As cooperativas também contribuem para o suporte técnico, logístico e financeiro das propriedades, fortalecendo o elo entre a cadeia de produção e seus agentes (Feyissa *et al.*, 2023). O conhecimento compartilhado neste processo pode determinar a permanência de pequenos produtores no setor, pois a tomada de decisão quando orientada por boas práticas de produção torna-se mais segura e eficiente (Feil *et al.*, 2023).

Vale ressaltar os benefícios associados a inserção de tecnologias avançadas neste setor. Nesse sentido, maiores níveis de produção podem ser obtidos com a melhoria dos processos de seleção genética dos animais, e até a própria automatização de processos relacionados a ordenha dos animais (Auchour *et al.*, 2020; Tassinari *et al.*, 2021). Observa-se aqui o desenvolvimento de tecnologias que agreguem a produção em termos de volume e qualidade do leite, mas também dedicadas a realização de boas práticas de produção pautadas no bem-estar animal e sustentabilidade ambiental (Almomani, 2020).

A seleção genética por exemplo, representa um dos pilares dos avanços tecnológicos neste setor (Masello *et al.*, 2021). Trabalhar mecanismos que viabilizem uma produção de alto

padrão de qualidade e baixo impacto ambiental pode ser realizado a partir do melhoramento genético de animais (Masello *et al.*, 2021). Também é possível a formação de rebanhos de alta produtividade e baixo consumo de recursos (Cardoso Consentini; Wiltbank; Sartori, 2021). A questão da saúde animal corresponde a um aspecto importante que pode ser beneficiado com esta tecnologia, a partir da geração de animais mais resistentes a doenças (Cardoso Consentini; Wiltbank; Sartori, 2021).

As tecnologias também são importantes neste contexto para o monitoramento dos processos de ordenha e alimentação dos animais (Brasier; Schwanke; Devries, 2023). A utilização de sensores e dispositivos de monitoramento podem auxiliar a coleta de informações em tempo real sobre o comportamento dos animais (Dutton-Register *et al.*, 2020). Isso é importante, pois o seguimento de uma rotina de alimentação e ordenha impacta os níveis de produtividade dos animais. Avanços em biotecnologia, automação e análise de dados tem contribuído para a melhoria da eficiência de propriedades leiteiras (Kovács; Szűcs, 2020; Fuentes *et al.*, 2020). Por exemplo, a aplicação de dispositivos pautados na Internet das Coisas (IoT) podem favorecer o monitoramento em tempo real de animais, otimizando processos de alimentação e ordenha (Oehm *et al.*, 2023). A análise de dados permite a melhoria da gestão das propriedades ao fornecer insights mais completos e informados (Kovács; Szűcs, 2020).

O planejamento financeiro pode ser facilitado mediante a utilização de tecnologias da informação, comunicando gestores e/ou produtores sobre custos operacionais, receitas e outros aspectos de produção (Maina *et al.* 2020). O acompanhamento financeiro da produção do leite pode ocorrer com base em plataformas digitais e aplicativos móveis que conectam os elos desta cadeia produtiva (Maina *et al.* 2020). No entanto, o acesso a estas tecnologias devem ser democratizados, para que os benefícios possam ser obtidos em todas as classes de produtores (Feyissa *et al.*, 2023).

A questão ambiental pode ser associada ao desenvolvimento de tecnologias sustentáveis no âmbito da pecuária leiteira (Froldi *et al.* 2022). Por se tratar de uma atividade que aborda uma multiplicidade de processos há uma gama de resíduos que podem ser reutilizados. Práticas de tratamento de dejetos e construção de biodigestores também beneficiam a geração de energia nestas propriedades (Leitgeb *et al.*, 2023). Já algumas tecnologias relacionadas a irrigação e nutrição balanceada permitem uma produção abundante de insumos para a alimentação dos animais, bem como o uso consciente de recursos naturais como a água (Erickson; Kalscheur, 2020).

A volatilidade de preços contempla um dos principais desafios econômicos relacionados a produção do leite no mercado global (Arvidsson Segerkvist *et al.*, 2020). Isso porque

oscilações na demanda e oferta, políticas comerciais, e até no clima podem ocorrer dificultando a estabilidade dos preços praticados no mercado (Maina *et al.* 2020). Este cenário impõe dificuldades para produtores avançarem em suas operações a longo prazo, causando a saída destes do setor em alguns casos (Feyissa *et al.*, 2023). A questão do acesso ao crédito também representa um impasse para pequenos e médios produtores, que se apresentam vulneráveis nesta situação de instabilidade de preços (Feyissa *et al.*, 2023).

Os desafios do setor também podem abordar questões técnicas associadas a práticas sanitárias adequadas e de gestão da qualidade do leite (Garvey, 2022). O desenvolvimento de doenças nos animais é um aspecto preocupante nas propriedades, principalmente de pequenos e médios produtores que não apresentam uma equipe especializada para o monitoramento da saúde os animais (Garvey, 2022). A prevenção de doenças requer o seguimento de protocolos sanitários rigorosos que dependem de uma rotina consistente nas propriedades. Estas doenças ao ocorrerem podem ocasionar a redução de produtividade dos animais, descarte do leite in natura, contaminação de animais sadios, morte dos animais, entre outros (Garvey, 2022).

As dificuldades de acesso a uma infraestrutura de qualidade contribuem para a instabilidade do setor (Feil *et al.*, 2023). Além disso, a própria infraestrutura pode impactar no alcance de melhores níveis de qualidade do leite produzido, fornecendo boas condições de armazenamento e transporte por exemplo (Lau *et al.*, 2022; Feil *et al.*, 2023). Entretanto, trata-se de fatores que incorrem em custos adicionais ao processo e muitas vezes não fazem parte da realidade de pequenos produtores por exemplo (Feyissa *et al.*, 2023). Logo, estes produtores acabam sendo limitados por questões econômicas ao acesso de novos mercados, expansão da produção e infraestrutura (Maina *et al.* 2020).

Todavia, ressalta-se as oportunidades de crescimento e inovação do setor que são estimuladas por uma demanda em expansão. A multiplicidade de produtos também é uma oportunidade para a cadeia de produção do leite e derivados (MAPA, 2024). As preferências dos consumidores incentivam a inovação neste setor, e agregam valor aos produtos, movimentando a economia (Talukder *et al.*, 2021). Nesse sentido é viabilizada a produção de leites orgânicos, com diferentes percentuais de proteína, sem lactose, derivados artesanais, entre outros produtos que elevam o padrão de qualidade observado e podem, portanto, aumentar as margens dos produtores e diversificar suas rendas (Talukder *et al.*, 2021).

A realização de políticas no âmbito da gestão da produção do leite auxilia na sustentabilidade das operações (Arvidsson Segerkvist *et al.*, 2020). Subsídios, incentivos fiscais e programas de acesso ao crédito e financiamento contemplam alguns dos resultados destas políticas (MAPA, 2024). Na prática estas políticas contribuem satisfatoriamente para a redução

das pressões econômicas sobre pequenos e médios produtores em períodos de baixa dos preços ou condições climáticas atípicas (Feil *et al.*, 2023). Processos relacionados ao melhoramento genético dos rebanhos, compra de insumos e investimentos na infraestrutura das propriedades podem ser realizados com base nestas políticas de incentivo (Arvidsson Segerkvist *et al.*, 2020).

O desenvolvimento e implementação de regulações na cadeia de produção do leite se faz presente na garantia da qualidade de produção (Nyokabi *et al.*, 2021). Dessa forma, são definidos requisitos a serem atendidos por todos os produtores, empresas de processamento e distribuidores (Nyokabi *et al.*, 2021). Como se trata de um alimento, cuidados são essenciais para evitar sua contaminação (Nyokabi *et al.*, 2021). Para tanto, são implementadas normas de alto rigor para os processos de ordenha, armazenamento e transporte do leite (Nyokabi *et al.*, 2021).

Cabe lembrar as regulações criadas no sentido de promover a preservação ambiental nas propriedades leiteiras. Trata-se de medidas de cunho sustentável que prezam pela produção do leite com menor impacto ambiental possível (Fuentes *et al.*, 2020). Dentre algumas medidas, há regulações que visam a gestão correta de dejetos, tratamento da água, otimização energética, redução de emissões e conservação do solo (Ilyas *et al.*, 2020; Fuentes *et al.*, 2020; Leitgeb *et al.*, 2023). Estas medidas ainda podem ocorrer com apoio de programas de treinamento e assistência técnica dos produtores (MAPA, 2024). Isso porque a capacitação de produtores pode gerar benefícios de cunho sustentável nas atividades de gestão dos rebanhos, nutrição animal e monitoramento da saúde dos animais (Arvidsson Segerkvist *et al.*, 2020). Práticas de extensão rural também são benéficas neste contexto, pois podem agregar valor à cadeia de produção do leite com a inserção de novas tecnologias e processos inovadores (Arvidsson Segerkvist *et al.*, 2020).

O crescimento da demanda por produtos lácteos no mundo representa uma oportunidade para que produtores possam estabelecer novos laços de mercado e comércio. Entretanto, conhecer a preferência dos consumidores finais, pode determinar seu sucesso na busca da integração entre cadeias de valor locais e globais (Talukder *et al.*, 2021). O acesso a demanda permite a correta diversificação da produção. Acentua-se aqui a existência de normas rígidas de qualidade e segurança alimentar, além de barreiras tarifárias para países que desejam competir internacionalmente (Nyokabi *et al.*, 2021). Desta forma, ajustes estratégicos podem ser utilizados através de práticas de marketing e comércio, facilitando este acesso ao mercado global de produtos lácteos pelos produtores (Talukder *et al.*, 2021).

Se tratando do histórico da produção e consumo de leite no mundo, este tem origem a 4.000 a.C., data em que as primeiras civilizações surgiram, os sumérios (Agroportal, 2020;

Canal do Leite, 2022). Nesse período a produção era baseada em sistemas agropecuários simples, porém, organizados. Além disso, seu consumo era reduzido uma vez que o leite cru é um produto de alta perecibilidade (Ciência do Leite, 2023). Logo mais, em meados do século XV, começaram o desenvolvimento de redes de comércio na Europa a partir da abertura das primeiras indústrias de laticínios na Suíça, intensificando a produção de alguns derivados como queijos e manteiga (Vilela *et al.*, 2017).

No Brasil a história de produção do leite é mais recente, e diretamente associada ao período de colonização (Canal do Leite, 2022). Com a chegada dos portugueses, estes trouxeram alguns hábitos europeus, dentre estes a criação de gado bovino e produção do leite (Agroportal, 2020). No começo a produção era estritamente para a subsistência das fazendas e de seus colonizadores. Ao longo do tempo, a produção foi se tornando mais popular entre a população a partir da produção de derivados do leite (Agroportal, 2020; Canal do Leite, 2022).

Com o início da Revolução Industrial no século XIX, a produção de leite na Europa e nos Estados Unidos sofreu uma expansão significativa, com a industrialização do setor e inserção de linhas de produção em larga escala (Vilela *et al.*, 2017). No Brasil, a Revolução Industrial também foi responsável pelos avanços do setor, especialmente com o desenvolvimento de novos protocolos de produção mais eficientes e tecnológicos (Canal do Leite, 2022). Todavia, o leite cru ainda era comercializado, sem uma preocupação devida com sua perecibilidade, o que gerava perdas de produção (Agroportal, 2020).

Neste sentido, destaca-se um grande avanço para a produção do setor em meados do século XX, quando o processo de pasteurização do leite foi desenvolvido (Ciência do Leite, 2023). A pasteurização trata-se de um processo de tratamento térmico, onde o leite é submetido a altas temperaturas para a eliminação de microrganismos prejudiciais à saúde e que causam a perda rápida do produto (Vilela *et al.*, 2017). Logo, mudanças no padrão de qualidade do produto foram verificadas neste período e ao longo do século XXI, bem como incentivos para o aumento da produção do leite e de seus derivados (Ciência do Leite, 2023).

Em um contexto mais recente, a produção de leite global tem avançado com uma demanda crescente por produtos lácteos. Isso se deve a alguns fatores como o crescimento populacional, a mudança nos padrões de consumo da população, a fatores ambientais, entre outros. (Canal do Leite, 2022). Especialmente em países como China e Índia que possuem populações volumosas, este comportamento pode ser melhor observado (Ciência do Leite, 2023). Associado a estes fatores, a adoção de práticas de produção mecanizadas tem incorporado maior eficiência no setor e a melhoria da qualidade do leite e derivados tem sido verificada (Agroportal, 2020).

No Brasil, a produção de leite ocorre em todas as regiões do país, com destaque para os estados da região Sul e Sudeste que apresentam os maiores volumes de produção (IBGE, 2023). Por possuir um clima favorável, com características geográficas e de vegetação diversificada, a produção de leite no país é favorecida (Vilela *et al.*, 2017; Feil *et al.*, 2023). Desta maneira, muitas famílias decidem se dedicar ao setor na busca por melhorias de renda e sobrevivência (Vilela *et al.*, 2017).

Especialmente nas regiões Sul e Sudeste do Brasil, a produção do leite é intensificada pela presença de um grande rebanho comparado ao de outras regiões do país (Canal do Leite, 2022). Além disso, nestas regiões a proximidade entre as propriedades e a indústria favorece o acesso dos produtores ao mercado de lácteos, com a possibilidade de comercialização do leite a melhores preços (IBGE, 2023). A automatização do manejo também é um aspecto fortemente presente em algumas propriedades destas regiões, o que dinamiza o escoamento de altos volumes de produção (Silvi *et al.*, 2021). O clima nestas regiões varia bastante, o que garante a possibilidade de produção em todo o ano (Vilela *et al.*, 2017; IBGE, 2023).

Para a região Centro-Oeste, um dos grandes polos de produção de grãos do país, verifica-se uma produção de leite com um modelo de manejo a pasto, com aproveitamento de pastagens naturais em grande parte das propriedades (Vilela *et al.*, 2017). Além disso, a possibilidade de aquisição de insumos para a alimentação dos animais a um custo reduzido é um fator que incentiva a produção nesta região (Ruviaro *et al.*, 2020). A combinação do plantio de grãos e pastagem para os animais é uma alternativa de redução de custo de produção, especialmente para pequenos produtores (Siqueira *et al.*, 2021).

No caso das regiões Norte e Nordeste, a produção do leite é impactada pelas condições climáticas e logísticas (Vilela *et al.*, 2017). Todavia, são verificados incentivos para a produção nestas regiões, com a adoção de novos modelos de manejo, raças de animais mais resistentes ao clima característico, entre outros fatores (Silveira *et al.*, 2022). Acentua-se o importante papel da inserção de modelos de manejo sustentáveis para a produção de leite nestas regiões, de forma a amenizar os impactos observados pelas mudanças climáticas (Zanin *et al.*, 2020).

2.4 Técnicas de apoio a tomada de decisão

Esta seção se dedicou a apresentação de técnicas de apoio a tomada de decisão.

2.4.1 Análise de Componentes Principais (PCA)

A Análise de Componentes Principais é uma técnica estatística multivariada que permite a redução do volume amostral sem a perda de informações significantes (Ba *et al.*, 2020). Para tanto, as variáveis originais são transformadas em um novo conjunto de variáveis denominadas componentes principais, que correspondem a combinações lineares das variáveis originais (Schiano *et al.*, 2020). Deste modo, não há relação entre fatores ou componentes, mas sim, uma relação entre as variáveis originais que são agrupadas em cada fator (Feyissa *et al.*, 2023).

A explicação de uma maior variância dos dados representa um dos objetivos da técnica (Brasier; Schwanke; Devries, 2023). Logo, a primeira componente principal trata-se da direção em que se observa uma maior variância, a segunda componente principal é a direção de máxima variância remanescente, e assim consecutivamente (Wairimu *et al.*, 2021). A readequação de dados em componentes beneficia a simplificação e visualização de dados amostrais, promovendo a identificação mais clara de tendências (Liu *et al.*, 2020).

Segundo de Lima Santos *et al.* (2021), a Análise de Componentes Principais é realizada a partir de um conjunto de p variáveis de n indivíduos. A Componente Principal 1 (W_1) será formada pela combinação linear das variáveis X_1, X_2, \dots, X_p de acordo com a equação (1):

$$W_1 = a_{11}X_1 + a_{12}X_2 + \dots + a_{1p}X_p \quad (1),$$

onde a_{ij} correspondem aos autovetores. Estes representam o peso de cada variável original sobre cada componente (de Lima Santos *et al.*, 2021). A componente será extraída de modo que $Var(W_1)$ seja a maior possível sujeita a restrição (2):

$$a_{11}^2 + a_{12}^2 + \dots + a_{1p}^2 = 1 \quad (2).$$

De forma análoga as demais componentes principais serão obtidas de modo que W_1, W_2, \dots, W_p não sejam correlacionadas. Caso existam p variáveis, existirão no máximo p componentes principais (Dittrich *et al.*, 2021). Acentua-se a importância na consideração da contribuição relativa de cada componente para a variabilidade total, isso porque a interpretação das componentes nem sempre ocorre diretamente (Feyissa *et al.*, 2023).

O processo de extração de componentes pode ser realizado de maneira arbitrária pela utilização de matrizes de correlação ou de covariância (Schiano *et al.*, 2020). Todavia, em alguns casos pode haver o destaque de algumas variáveis originais com altos escores de variâncias, o que pode enviesar a análise da componente e das etapas seguintes, logo sugere-se

a prevalência por uma matriz de correlação (Ba *et al.*, 2020). Trata-se de uma etapa importante, responsável pela homogeneidade das variáveis originais de interesse. Segundo Brasier; Schwanke; Devries, 2023, a matriz de correlação é expressa por uma matriz simétrica conforme a equação (3):

$$C = \begin{pmatrix} c_{11} & c_{12} & \dots & c_{1p} \\ c_{21} & c_{22} & \dots & c_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ c_{p1} & c_{p2} & \dots & c_{pp} \end{pmatrix} \quad (3),$$

onde o elemento c_{ii} da diagonal principal corresponde a correlação da variável X_i e o termo externo a diagonal principal c_{ij} representa a correlação entre as variáveis X_i e X_j .

A variância das componentes principais corresponde aos autovalores da matriz C (termos c_{ij}). Os autovalores significam a contribuição relativa de cada componente na explicação da variação total dos dados (Brasier; Schwanke; Devries, 2023). A soma dos autovalores (λ_p) é igual à soma dos elementos da diagonal principal da matriz C, conforme (4):

$$\lambda_1 + \lambda_2 + \dots + \lambda_p = c_{11} + c_{22} + \dots + c_{pp} \quad (4),$$

onde λ_p é a variância da componente principal W_p . Além disso, é comum a configuração das variáveis X_1, X_2, \dots, X_p para que tenham médias nulas e variâncias unitárias no início das análises (Brasier; Schwanke; Devries, 2023). Desta maneira a matriz C corresponderá ao formato apresentado em (5):

$$C = \begin{pmatrix} 1 & c_{12} & \dots & c_{1p} \\ c_{21} & 1 & \dots & c_{2p} \\ \vdots & \vdots & 1 & \vdots \\ c_{p1} & c_{p2} & \dots & 1 \end{pmatrix} \quad (5),$$

onde a soma dos elementos da diagonal principal corresponde ao total de variáveis X.

2.4.2 Análise Envoltória de Dados (DEA)

A Análise Envoltória de Dados trata-se de uma técnica multivariada pautada na manipulação de modelos matemáticos não paramétricos (Sefeedpari; Shokoohi; Pishgar-

komleh, 2020). Logo, é uma técnica poderosa de avaliação de desempenho que se destaca pela análise de eficiência relativa de decision making units (DMUs) (Siafakas *et al.*, 2019). A Análise Envoltória de Dados dedica-se a situações em que múltiplas entradas e saídas estão envolvidas, onde o desafio é determinar o quão eficientemente uma DMU converte suas entradas em saídas (Ilyas *et al.*, 2020).

As DMUs, nesse sentido, correspondem a unidades produtivas tomadoras de decisão em diferentes contextos (Yu *et al.*, 2023). Isso se deve a alta flexibilidade de aplicação da técnica que não se limita a utilização de uma função de produção específica, de modo a atuar em diferentes contextos (Kouriati *et al.*, 2023), inclusive na pecuária leiteira. A abordagem não paramétrica contribui para a geração de fronteiras de produção eficientes para cada uma das DMUs analisadas, logo, conforme Barros *et al.* (2022) a eficiência é calculada mediante a distância percebida entre cada DMU e sua fronteira de eficiência.

Uma característica relevante da Análise Envoltória de Dados corresponde a sua capacidade de identificação de unidades pertencentes a fronteira de eficiência (Pedolin *et al.*, 2023). Nestes casos, trata-se de unidades cem por cento eficientes, sendo consideradas como referências para as demais unidades não pertencentes a fronteira (Soteriades *et al.*, 2020). Já as DMUs consideradas ineficientes podem ser comparadas e avaliadas em termos de melhorias potenciais, ou seja, a técnica permite o cálculo de valores alvos para cada variável original considerada e compara os esforços que cada DMU ineficiente deve realizar para alcançá-los (Oğuz; Yener, 2019).

Cabe lembrar a aderência desta técnica a conceitos como produtividade e eficiência técnica (Kouriati *et al.*, 2023). A produtividade trata-se de quão bem os insumos serão consumidos para a geração de produtos, ou seja, é a medida de eficiência para o gasto de recursos (Barros *et al.*, 2022). A eficiência técnica é responsável pela identificação e eliminação de folgas do modelo, pois compara a produtividade atual com a produtividade mais adequada de acordo com a fronteira de eficiência estipulada (Sefeedpari; Shokoohi; Pishgar-komleh, 2020). Destaca-se aqui a diferença entre eficiência técnica e econômica, ou seja, para que um processo seja considerado tecnicamente eficiente é necessário que haja o menor consumo de recursos para o mesmo nível de produção. Por outro lado, este é classificado como economicamente eficiente caso permita o mesmo nível produção ao menor custo possível (Ilyas *et al.*, 2020).

A história da Análise Envoltória de Dados tem origem na década de 1950, em que podem ser listadas as contribuições da teoria da produção. Logo, alternativas de produção eram propostas a partir de reflexões sobre métodos matemáticos de programação para a alocação

eficiente de recursos na economia (Siafakas *et al.*, 2019). Importantes avanços foram registrados neste período, dentre eles, o surgimento do método simplex, fruto da reestruturação de um problema de programação linear (Yu *et al.*, 2023). Além disso, novamente a teoria da produção se faz presente na Análise Envoltória de Dados, lembrando o conceito de rendimentos de escala (Oğuz; Yener, 2019).

Os rendimentos de escala referem-se à relação entre o aumento da produção e o aumento proporcional nos insumos em um ambiente de produção, por exemplo (Barros *et al.*, 2022). Dito isso, segundo Yu *et al.* (2023), há três cenários possíveis: rendimentos crescentes, constantes e decrescentes de escala. Os rendimentos crescentes de escala ocorrem quando uma DMU aumenta proporcionalmente seus insumos e sua produção é aumentada em uma proporção maior. Os rendimentos constantes de escala ocorrem quando aumentos proporcionais dos insumos resultam em aumentos proporcionais na produção. Por fim, os rendimentos decrescentes de escala ocorrem quando uma DMU aumenta proporcionalmente seus insumos e sua produção é aumentada em uma proporção menor.

Na prática, caso uma DMU esteja localizada na fronteira de eficiência, esta apresenta rendimentos constantes de escala (Kouriati *et al.*, 2023). Caso a DMU esteja abaixo da fronteira de eficiência, há a existência de folgas no processo, e conseqüentemente, esta unidade poderá aumentar sua produção mediante a otimização do consumo de insumos, o que configura um cenário de rendimentos crescentes de escala. Já caso a DMU esteja localizada acima da fronteira de eficiência, ajustes no consumo de recursos podem ser realizados para evitar perdas no processo causados pela ineficiência associada aos rendimentos decrescentes de escala.

Se tratando dos tipos de modelos para a Análise Envoltória de Dados, podem ser listados o modelo CCR (desenvolvido por Charnes, Cooper e Rhodes) e o modelo BCC (desenvolvido por Banker, Charnes e Cooper). O modelo CCR assume que as entradas e saídas das DMUs consideradas são proporcionais, ou seja, retornos constantes de escala e não há desperdício de recursos (Oğuz; Yener, 2019). Logo, o modelo CCR trata-se de uma alternativa importante para a análise do consumo consciente de recursos disponíveis (Yu *et al.*, 2023). Já o modelo BCC é mais abrangente ao permitir ineficiências tanto para insumos quanto produtos e rendimentos variáveis de escala (Pedolin *et al.*, 2023). Ou seja, o modelo BCC generaliza o modelo CCR, na medida em que a eficiência pode ser alcançada tanto pelo consumo adequado de insumos quanto pela maximização da produção (Soteriades *et al.*, 2020).

A orientação do modelo também é uma classificação pertinente para a Análise Envoltória de Dados, podendo ser de dois tipos: orientado a insumo e a produto (Barros *et al.*, 2022). Um modelo orientado a insumo dedica-se a redução de insumos mantendo-se constante

a produção (Kouriati *et al.*, 2023). Por outro lado, um modelo orientado a produto preza pelo aumento do nível de produção mantendo o consumo de insumos constante (Ilyas *et al.*, 2020).

2.4.3 Simulação de Monte Carlo (SMC)

A Simulação de Monte Carlo trata-se de uma técnica estatística capaz de calcular resultados probabilísticos em diferentes áreas do conhecimento (Yapicioğlu; Yeşilnacar, 2020). Sua capacidade de lidar com variáveis aleatórias a partir de distribuições de probabilidade confere à técnica a geração de um conhecimento holístico (Leitgeb *et al.*, 2023). As variáveis aleatórias representam os valores que podem ser obtidos em um experimento aleatório, existem variáveis aleatórias discretas e contínuas (Masello *et al.*, 2021). As variáveis aleatórias discretas determinam valores finitos ou infinitos contáveis, por exemplo, o número de clientes em uma fila de espera (Rasmussen *et al.*, 2021). As variáveis aleatórias contínuas, por outro lado podem assumir um número infinito de valores dentro de um intervalo específico, por exemplo, a altura de um indivíduo (Lau *et al.*, 2022).

A construção de cenários de análise representa a base desta técnica, permitindo uma tomada de decisão mais assertiva pelos gestores (Jebari *et al.*, 2022). Uma particularidade desta técnica consiste na possibilidade de trabalhar com modelos complexos e não-lineares, que contemplem a interrelação entre diferentes variáveis (Yapicioğlu; Yeşilnacar, 2020). Segundo Leitgeb *et al.*, (2023), trata-se de um experimento amostral com o objetivo de estimar a distribuição dos resultados de uma variável de saída, a partir de uma ou mais variáveis de entrada que apresentam um comportamento orientado por distribuições ou funções de probabilidade. As funções de probabilidade são ferramentas que descrevem a probabilidade de ocorrência de diferentes eventos em um espaço amostral (Masello *et al.*, 2021).

A priori, as funções de probabilidade podem ser divididas em dois grupos, a saber, as funções de massa de probabilidade e as funções de densidade de probabilidade (Lau *et al.*, 2022). No caso das funções de massa de probabilidade, estas são utilizadas para variáveis aleatórias discretas e atribuem a cada valor da variável aleatória a sua probabilidade de ocorrência (Yapicioğlu; Yeşilnacar, 2020). Já as funções de densidade são utilizadas para variáveis aleatórias contínuas, e indicam a probabilidade de ocorrência de um evento a partir da área sob a curva da função de probabilidade entre dois pontos específicos (Jebari *et al.*, 2022).

Algumas das funções de distribuição de probabilidade mais utilizadas são, por exemplo, as funções de distribuição normal, triangular, pert, binomial, uniforme e exponencial

(Rasmussen *et al.*, 2021). Ressalta-se aqui a existência de uma infinidade de funções de probabilidade, cada qual com um objetivo de aplicação distinto (Leitgeb *et al.*, 2023). Todavia, para que se obtenha resultados que representem de fato a realidade estudada é necessário que os parâmetros destas funções sejam bem definidos, bem como ocorra uma indicação clara das variáveis utilizadas e incertezas do modelo (Lau *et al.*, 2022).

No que se refere as etapas de aplicação da técnica, segundo Masello *et al.* (2021) inicialmente há a definição do modelo de simulação, incluindo a especificação de variáveis de entrada e saída, e dos parâmetros das funções de distribuição de probabilidade para cada variável de entrada. Logo após, na etapa 2, há a geração de amostras aleatórias conforme as distribuições de probabilidade predeterminadas. Posteriormente, a etapa 3 se dedica a compilação da simulação, utilizando os valores das variáveis aleatórias de entrada para calcular os resultados. Por fim, as etapas 4 e 5 correspondem a repetição do processo e a análise estatística (Masello *et al.*, 2021).


2.4.4 Redes Neurais Artificiais (RNAs)

O surgimento das redes neurais artificiais remonta a década de 1940, período em que foi desenvolvido um modelo matemático simplificado do funcionamento do cérebro humano (Haykin, 2001). Nesta ocasião, destaca-se os trabalhos de Warren McCulloch e Walter Pitts com a proposição de um modelo matemático de neurônios artificiais. Além disso, no ano de 1943 estes autores descreveram em seus trabalhos um modelo simplificado do funcionamento de neurônios biológicos (Haykin, 2001). Posteriormente, Frank Rosenblatt entre as décadas de 1940-1960 desenvolveu o *Perceptron*, que consiste em uma rede neural de camada única, capaz de aprender e realizar tarefas simples de classificação (Braga; Ludermir; Carvalho, 2000).

Todavia, o desenvolvimento significativo das RNAs ocorreu a partir dos anos 1980 com o avanço da computação (Silva, 2016). Novas arquiteturas de redes aliadas a disponibilidade de poder computacional impulsionaram os estudos sobre RNAs neste período. Destaca-se aqui o desenvolvimento do algoritmo de retropropagação (*backpropagation*) para treinamento de redes neurais multicamadas (Braga; Ludermir; Carvalho, 2000). Desde o final do século XX até os dias atuais, as RNAs têm sido aplicadas a uma variedade de campos, incluindo reconhecimento de padrões, processamento de linguagem natural, visão computacional, medicina, finanças, reconhecimento de imagens, tradução automática, geração de texto, entre outros (Haykin, 2001; Silva, 2016).

As RNAs contemplam modelos computacionais inspirados na estrutura neural de organismos inteligentes ou neurônios biológicos, que adquirem conhecimento por meio da experiência (Braga; Ludermir; Carvalho, 2000). A Figura 8 representa a estrutura de um neurônio biológico. A estrutura de um neurônio artificial se assemelha a de um neurônio biológico. Dessa forma, os dendritos são comparáveis aos inputs da rede, o corpo celular é comparável a unidade de soma, o axônio ao output responsável pela propagação de sinal, e as sinapses comparáveis às conexões com outros neurônios (Silva, 2016). Em suma, as RNAs consistem em uma arquitetura de nós interconectados onde cada nó (neurônio artificial) recebe entradas, realiza uma operação matemática neles e transmite a saída para os neurônios subsequentes (Naqvi *et al.*, 2022). A informação flui através da rede, passando por camadas de neurônios (Slob; Catal; Kassahun, 2021; Oehm *et al.*, 2023).

Figura 8 - Estrutura de um neurônio biológico



Fonte: Silva (2016)


Segundo Silva (2016) há vários tipos de redes neurais, que se diferenciam pela estrutura, pelos tipos de cálculos efetuados dentro dos neurônios e pelos algoritmos de treinamento. A Figura 9 representa uma rede *perceptron* simples, que corresponde a forma básica de uma rede neural artificial. A rede *perceptron* simples apresenta uma arquitetura feedforward, onde o fluxo de informações ocorre no sentido da camada de entrada à camada de saída (Haykin, 2001). Neste tipo de rede não há a formação de ciclos de realimentação. Além disso, neste caso a quantidade de neurônios a serem utilizados na camada de saída (m) será determinado pela quantidade saídas que a rede deve fornecer.

Figura 9 - Rede *perceptron* simples

(Continua)


Figura 9 - Rede *perceptron* simples

(Conclusão)



Fonte: Silva (2016)

No que se refere às redes *perceptron* de múltiplas camadas (PMC), estas são caracterizadas pela presença de pelo menos uma camada intermediária (escondida) de neurônios, situada entre a camada de entrada e a respectiva camada neural de saída (Haykin, 2001). A Figura 10 representa a estrutura de uma rede *perceptron* de múltiplas camadas. Neste tipo de rede a quantidade de neurônios da camada de saída também é definida com base na quantidade de sinais de saída. Acentua-se aqui que a quantidade de camadas intermediárias bem como a quantidade de neurônios contidos em cada uma das camadas é definido com base no nível de complexidade do problema, quantidade e qualidade dos dados disponíveis para análise (Braga; Ludermir; Carvalho, 2000).

Figura 10 - Rede *perceptron* multicamadas

Fonte: Silva (2016)

Os estímulos ou sinais são apresentados à rede em sua camada de entrada. As camadas intermediárias, por sua vez, extraem a maioria das informações referentes ao seu comportamento e as codificam por meio dos pesos sinápticos e limiares de seus neurônios, formando assim uma representação própria do ambiente em que está inserido o referido sistema a ser tratado (Silva, 2016). Finalmente, os neurônios da camada de saída recebem os estímulos advindos dos neurônios da última camada intermediária, produzindo um padrão de resposta que será a saída disponibilizada pela rede (Braga; Ludermir; Carvalho, 2000).

A fase de treinamento da rede trata-se de um processo de ajuste fino dos parâmetros de cálculo, a fim de obter maior acurácia nos resultados produzidos pela rede. Logo, este processo ocorre com base no treinamento dos dados e no algoritmo de treinamento utilizado. O algoritmo de treinamento seleciona diversos conjuntos de parâmetros de cálculo e avalia cada um aplicando a rede a cada caso do treinamento com o objetivo de adequar as respostas fornecidas pela rede (Haykin, 2001). Assim, os conjuntos de parâmetros são interpretados como tentativas, sendo o algoritmo de treinamento responsável por selecionar novos conjuntos de parâmetros com base nos resultados de tentativas anteriores (Silva, 2016). Este processo de ajuste ocorre mediante um processo de treinamento supervisionado, onde cada amostra de dados selecionada obtém-se uma resposta de saída desejada (Silva, 2016).


A partir do avanço dos estudos sobre RNAs foi necessário criar algoritmos capazes de treinar redes *perceptron* multicamadas para o processamento de informações. Logo, foi desenvolvido o algoritmo de retropropagação (*backpropagation*) que funciona em duas etapas: para frente (forward) e para trás (backward) (Haykin, 2001). A Figura 11 ilustra as fases deste treinamento para uma rede *perceptron* multicamadas.

Figura 11 - Fases de treinamento da rede *perceptron* multicamadas

(Continua)

Figura 11 - Fases de treinamento da rede *perceptron* multicamadas

(Conclusão)



Fonte: Silva (2016)

Neste tipo de rede neural o algoritmo de retropropagação baseado no cálculo automatizado do gradiente descendente percorre a rede em ambos os sentidos, para frente e para trás pelas camadas intermediárias, buscando diminuir a taxa de erro até convergir a melhor solução. A melhor solução será a que apresentar maior acurácia e menor taxa de erro (Silva, 2016). Em suma, os pesos de cada neurônio são iniciados de forma aleatória; os sinais de entrada percorrem a rede até o fim; viabilizando o cálculo da taxa de erro. A taxa de erro corresponde a diferença entre saídas da rede e do resultado esperado, ou seja, entre o real e o predito (Braga; Ludermir; Carvalho, 2000). Dessa maneira, o erro é propagado de volta, e há a atualização dos pesos, podendo este processo se repetir por diversas vezes (Haykin, 2001).

Neste contexto, a função de ativação dos neurônios realizam um importante papel, decidindo qual neurônio deverá ser ativado ou não (Silva, 2016). Ou seja, se o sinal de entrada do neurônio deve ser considerado ou ignorado. Uma função de ativação é responsável pela transformação não-linear ao longo do sinal de entrada da rede (Braga; Ludermir; Carvalho, 2000). Logo, o output de uma camada de neurônios será o input da camada posterior. A função de ativação promove a transformação não-linear nos dados de entrada, tornando possível o aprendizado e execução de tarefas mais complexas (Haykin, 2001).

Em relação as parcelas de erro geradas no processo de treinamento e teste, estas podem ser representadas por uma superfície de erro, a partir de uma função custo por exemplo. A função de custo é a soma de todos os erros gerados pelo modelo ao comparar as previsões feitas

pelo modelo e os valores reais (Haykin, 2001). Logo, a avaliação do desempenho global do algoritmo *backpropagation* pode ser efetuada através do cálculo do “erro quadrático médio” (Silva, 2016). A função do erro quadrático é utilizada para medir o desempenho local associado aos resultados produzidos pelos neurônios de saída de acordo com os dados imputados (Haykin, 2001).

A quantidade de neurônios nas camadas de entrada, saída e camada oculta, função de ativação, função de custo e algoritmo de treinamento trata-se de parâmetros a serem definidos anteriormente a realização do treinamento (Braga; Ludermir; Carvalho, 2000). Logo, na camada de entrada a quantidade de neurônios corresponde a mesma quantidade das variáveis de entrada. Já a quantidade de neurônios para a camada de saída considera-se o mesmo número da classes dos dados (Silva, 2016). Já a quantidade de neurônios na camada oculta não há regra definida, podendo ser utilizada a raiz quadrada da quantidade de amostras ou média da quantidade de neurônios das camadas de entrada e saída (Braga; Ludermir; Carvalho, 2000).

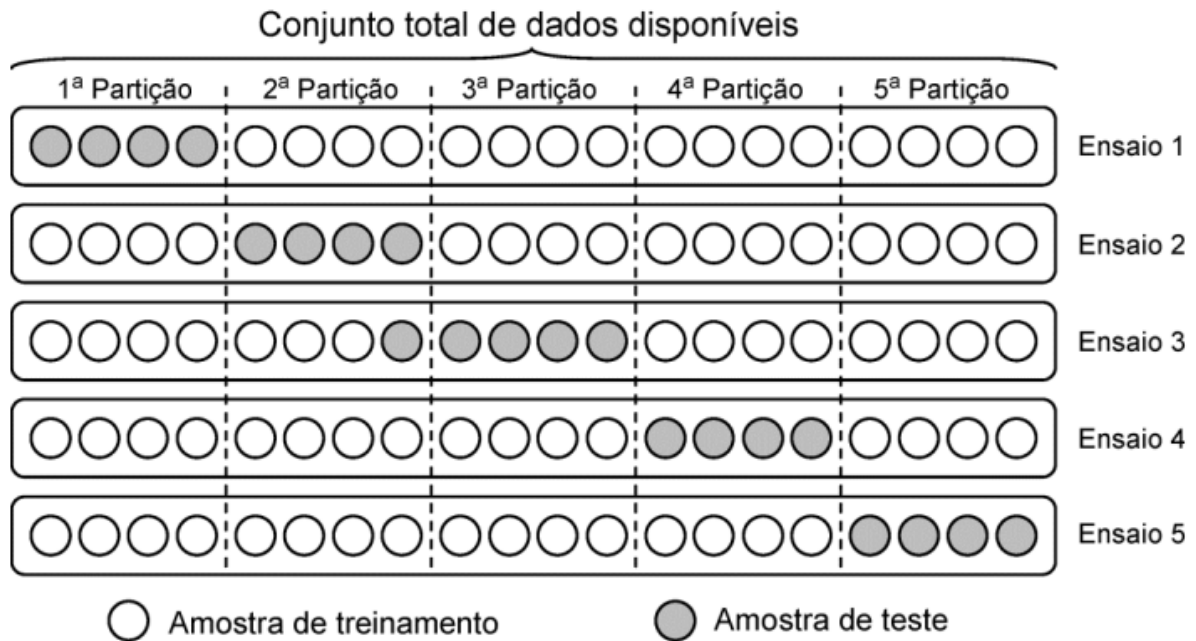
O pré-processamento de dados para a etapa de treinamento considera a conversão dos dados para números, o balanceamento das classes, a normalização dos dados e a divisão do conjunto de dados em subconjuntos como treinamento e teste, ou treinamento, validação e teste (Braga; Ludermir; Carvalho, 2000). O processo de validação pode ocorrer através da validação cruzada, que consiste em separar o conjunto de dados em subconjuntos mutuamente exclusivos, sendo um deles para treino e os outros para teste e validação do desempenho do modelo (Silva, 2016). A aplicação desta técnica pode ser pautada na separação aleatorizada de k subconjuntos de mesmo tamanho (k -fold) (Silva, 2016). O modelo é treinado com $k-1$ subconjuntos e testado com o conjunto restante. Esse processo é repetido k vezes. A Figura 12 representa o método de validação cruzada pelo k -fold.

Figura 12 - Método de validação cruzada com k subconjuntos

(Continua)

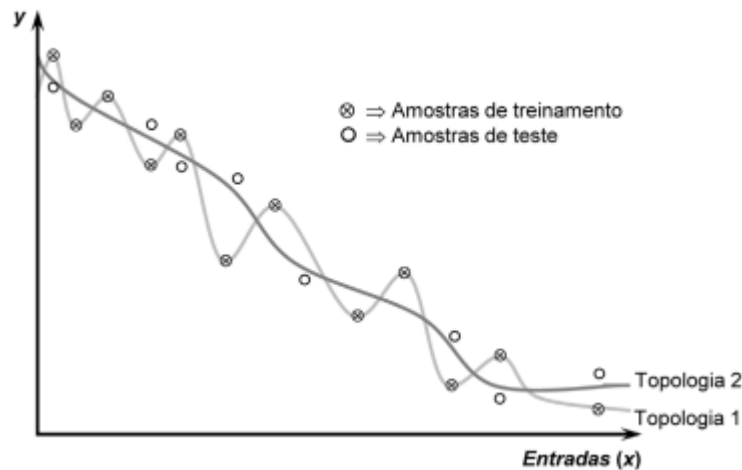
Figura 12 - Método de validação cruzada com k subconjuntos

(Conclusão)



Fonte: Silva (2016)

A técnica de validação cruzada é útil, pois permite avaliar a capacidade de generalização dos modelos de machine learning (Silva, 2016). Acentua-se aqui a possível ocorrência de problemas nos ajustes dos dados ao modelo, como o *overfitting* (sobreajuste) e o *underfitting* (subajuste). A Figura 13 representa o comportamento de sobreajuste ou *overfitting* em uma rede *perceptron* multicamadas.

Figura 13 - Comportamento da rede *perceptron* multicamadas em *overfitting*

Fonte: Silva (2016)

O *overfitting* (sobreajuste) acontece quando a rede é treinada em excesso. Neste caso, o modelo acaba decorando os dados de treinamento, e obtém uma tentativa frustrada ao tentar aplicar estas regras aos dados de teste (Silva, 2016). Logo, o que se observa é uma alta variância e baixo viés, resultando em altos valores de acurácia do modelo para treinamento. Entretanto, com a entrada de novos dados para teste o modelo não consegue prever de forma eficaz, ou seja, não generaliza bem com novos conjuntos de dados (Braga; Ludermir; Carvalho, 2000). Já o *underfitting* (subajuste) ocorre quando a rede é muito simples em relação a complexidade do problema. Isto é caracterizado por um alto viés e baixa variância do modelo de treinamento, o que reduz a acurácia. Além disso, trata-se de um baixo ajuste do modelo aos dados, não conseguindo prever praticamente nada correto (Silva, 2016).

A fim de avaliar o desempenho das redes neurais, há algumas métricas que podem ser consideradas, tais como métricas de regressão (MSE – Erro quadrático médio; MAE – Erro absoluto médio; RMSE – Raiz do erro quadrático médio) e métricas de classificação (Acurácia; Precisão; Recall; F1-score) (Braga; Ludermir; Carvalho, 2000). As equações (6), (7), (8), (9), (10), (11) e (12) representam as métricas de regressão e de classificação respectivamente.

$$MSE = \sum_{i=1}^n \frac{(y'_i - y_i)^2}{n} \quad (6)$$

$$MAE = \sum_{i=1}^n \frac{|y_i - y'_i|}{n} \quad (7)$$

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(y'_i - y_i)^2}{n}} \quad (8)$$

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (9)$$

$$Precisão = \frac{VP}{VP + FP} \quad (10)$$

$$Recall = \frac{VP}{VP + FN} \quad (11)$$

$$F1 - Score = \frac{2 * Precisão * Recall}{Precisão + Recall} \quad (12)$$

Em (6), (7) e (8), y'_i corresponde ao valor do output previsto como resultado de saída da rede, já y_i se refere ao valor real correspondente a este output. A acurácia (9) indica uma performance geral do modelo, ou seja, dentre todas as classificações, quantas o modelo classificou corretamente. A precisão (10) indica dentre todas as classificações de classe Positivo que o modelo fez, quantas estão corretas. O recall/revocação/sensibilidade (11) indica dentre todas as situações de classe Positivo como valor esperado, quantas estão corretas. Já o F1-Score (12) corresponde à média harmônica entre as métricas de precisão e recall. A média harmônica é preferível, pois está muito mais próxima dos menores valores do que uma média aritmética simples. Ou seja, quando se tem um F1-Score baixo, é um indicativo de que ou a precisão ou o recall está baixo (Braga; Ludermir; Carvalho, 2000; Silva, 2016).

Esta avaliação de desempenho pode ainda ser expressa a partir de uma matriz de confusão. Nela são apresentadas as classificações reais e previstas, o que permite uma melhor interpretação visual das métricas de regressão e classificação (Braga; Ludermir; Carvalho, 2000). A Figura 14 representa um esboço da matriz de confusão.

Figura 14 - Matriz de confusão

		Detectada	
		Sim	Não
Real	Sim	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Fonte: Silva (2016)

De maneira complementar a análise de desempenho, há também a chamada Curva ROC (Curva Característica de Operação do Receptor), esta é formada pelo eixo Y (Sensibilidade) versus eixo X (Especificidade). A especificidade indica dentre todas as situações de classe Negativo como valor esperado, quantas estão corretas (Silva, 2016). Logo, tem-se a máxima da curva ROC, que diz que quanto mais para cima e esquerda, melhor o teste, ou quanto maior a Área sob a curva ROC (AUC), melhor o teste (Braga; Ludermir; Carvalho, 2000).

É importante destacar que a aplicação de redes neurais apresenta limitações como a necessidade de uma base de dados densa, a capacitação das partes interessadas configuração adequada e o nível de tecnologia compatível (Almomani, 2020). A prática dessa técnica é abrangente, e aborda questões como o reconhecimento de objetos, tradução automática, reconhecimento de fala, previsão de doenças, detecção de fraudes, controle de processos e manutenção preditiva, por exemplo (Auchour *et al.*, 2020; Tassinari *et al.*, 2021). De forma

geral, a utilização da técnica tem contribuído para avanços em diversas áreas de conhecimento, demonstrando alta capacidade de solução de problemas complexos e não-lineares (Zheng *et al.*, 2023).

A aplicabilidade desta técnica também se estende à pecuária leiteira, isso porque diversos processos neste setor apresentam padrões observados de comportamento e que podem ser aprendidos pelas redes (Tassinari *et al.*, 2021). Por exemplo, as redes podem beneficiar atividades de monitoramento e diagnóstico, a partir da identificação dos padrões de alimentação, rotina e saúde dos animais (Ahour *et al.*, 2020). Também há ganhos com a utilização das redes para a melhoria da qualidade do leite, pois a técnica permite o acompanhamento de variáveis importantes como o teor de gordura, proteína e contagem de células somáticas (Oehm *et al.*, 2023). As condições de manejo também podem ser automatizadas ainda mais com a introdução das redes neurais artificiais, através da identificação de anomalias, ajustes de manutenção preditiva, bem como a otimização da ordenha considerando características individuais dos animais (Zheng *et al.*, 2023).

3 PROCEDIMENTOS METODOLÓGICOS

Nesta seção foram abordados os procedimentos metodológicos do estudo. Estes foram compostos pelo tipo de pesquisa, o objeto de estudo, a amostra de pesquisa, os procedimentos e técnicas de coleta de dados e, por fim, a análise e interpretação destes.

3.1 Tipo de pesquisa

Este estudo apresentou caráter descritivo, uma vez que esta pesquisa se propôs a descrever as características de um fenômeno ou a relação entre variáveis estudadas. Segundo Thomas (2021), uma pesquisa descritiva preza pela maior riqueza de detalhes sobre um tema já estudado, de modo a analisar, interpretar e descrever características de um fenômeno. Pandey e Pandey (2021) complementam que a pesquisa descritiva apresenta outras vantagens além de uma compreensão detalhada de dado fenômeno, garante objetividade, auxilia na identificação de padrões, favorece o planejamento de pesquisas futuras e a aplicabilidade prática, bem como permite maior facilidade de análise e validação de teorias.

Em relação a abordagem de pesquisa, este estudo foi construído nos moldes de uma pesquisa quantitativa, pois trata-se de um estudo focado na coleta e análise de dados numéricos. Segundo Thomas (2021), a pesquisa quantitativa está pautada na utilização de modelos matemáticos e/ou estatísticos e permite a contagem, medição e classificação dos dados. Conforme Davidavičienė (2018) a pesquisa quantitativa ainda contribui para a objetividade do estudo, confere maior neutralidade do pesquisador sobre o fenômeno de estudo e garante a replicabilidade da pesquisa.

O estudo ainda apresentou uma lógica indutiva, uma vez que este se propôs a encontrar conclusões gerais a partir de observações específicas e/ou de uma base de dados restrita. De acordo com Daniel (2018), a lógica indutiva favorece a identificação de padrões e o desenvolvimento de teorias ou generalizações. Para Hosseinzadeh Lotfi *et al.* (2023) uma pesquisa indutiva possibilita o surgimento de novas descobertas e insights a partir de uma linguagem aberta e flexível.

3.2 Objeto de estudo e amostragem

De acordo com Pandey e Pandey (2021) o objeto de estudo aborda os limites da pesquisa, de modo a definir qual a área de interesse o pesquisador deseja explorar. O objeto de

estudo diz sobre o tema ou fenômeno de estudo, além de contribuir com a qualidade e relevância da pesquisa (Thomas, 2021). Logo, o objeto de estudo desta pesquisa abordou a eficiência da cadeia produtiva do leite no Brasil, com foco em fatores impactantes na produção do leite. Alguns aspectos foram determinantes para a complementação do estudo, tais como, o conhecimento dos métodos de produção, modelos de gestão vigentes, eficiência operacional, indicadores de desempenho e sustentabilidade.

Conforme Davidavičienė (2018), a amostragem de pesquisa se refere ao processo de seleção de uma parte representativa da realidade a ser estudada. A amostragem permite maior rigor de análise a partir de um conjunto menor de dados que serão analisados para a obtenção de conclusões sobre o estudo (Thomas, 2021). Vale ressaltar o impacto de algumas técnicas de pesquisa sobre a etapa de amostragem como, por exemplo, a técnica de Análise Envoltória de Dados em que é necessário um volume de unidades de tomada de decisão três vezes maior que o número de indicadores selecionados (Hosseinzadeh Lotfi *et al.*, 2023; Kouriaty *et al.*, 2023). Considerando que no Brasil, segundo o MAPA (2024), existem mais de 1 milhão de propriedades leiteiras distribuídas por todos os estados, este estudo apresenta como amostra de pesquisa um conjunto de 864 produtores de leite distribuídos em 18 estados brasileiros, correspondentes a base de dados da Companhia do Leite.

3.3 Procedimentos e técnicas de coleta de dados

Os procedimentos e as técnicas empregadas na etapa de coleta de dados são fundamentais para o alcance de uma amostra representativa que reflita as características essenciais do objeto de estudo (Daniel, 2018). Assim, o estudo realizou a coleta de dados secundários obtidos a partir da base de dados da Companhia do Leite no Brasil. Neste estudo as variáveis originais de análise foram dispostas nas dimensões de desempenho, a saber, produção, receita e custos operacionais. Segundo Delios *et al.* (2023), os dados secundários correspondem a informações já coletadas e registradas, disponíveis através de bancos de dados públicos ou de empresas privadas.

Cabe lembrar que foram coletados os dados referentes ao ano de 2022 por se tratar do último ano de dados completos apresentados pela base, fato que agrega o estudo com a geração de resultados atualizados que possam refletir dinâmica de produção do leite em diferentes regiões brasileiras. O uso de dados secundários também significa uma boa estratégia para a economia de tempo e outros recursos, desde que seja possível o acesso às informações necessárias (Delios *et al.*, 2023). Todavia, protocolos, termos de uso e condições de acesso a

esses dados devem ser respeitados como forma de garantir a qualidade, confiabilidade e relevância da pesquisa.

3.4 Análise e interpretação dos dados

Este estudo foi realizado em um período de 24 meses. Além disso, foram analisados 18 estados produtores de leite no Brasil, correspondentes ao total de regiões atendidas pela Companhia do Leite. Logo, a fim de cumprir com todos os objetivos propostos neste estudo, a pesquisa foi dividida em seis estágios de realização, a saber:

- 1) **Primeiro estágio:** aplicação da Análise de Componentes Principais e proposição de índices de desempenho global para a gestão das regiões produtoras de leite;
- 2) **Segundo estágio:** aplicação da técnica de Análise Envoltória de Dados;
- 3) **Terceiro estágio:** reaplicação da Análise de Componentes Principais, nas variáveis de entrada e saída da Análise Envoltória de Dados, com base na opinião e experiência dos pesquisadores e demais indivíduos que contribuirão para este projeto;
- 4) **Quarto estágio:** realização de uma análise complementar e comparativa entre os resultados obtidos a partir do uso da Análise de Componentes Principais e da Análise Envoltória de Dados;
- 5) **Quinto estágio:** Aplicação da Simulação de Monte Carlo;
- 6) **Sexto estágio:** Aplicação da técnica de Redes Neurais Artificiais.

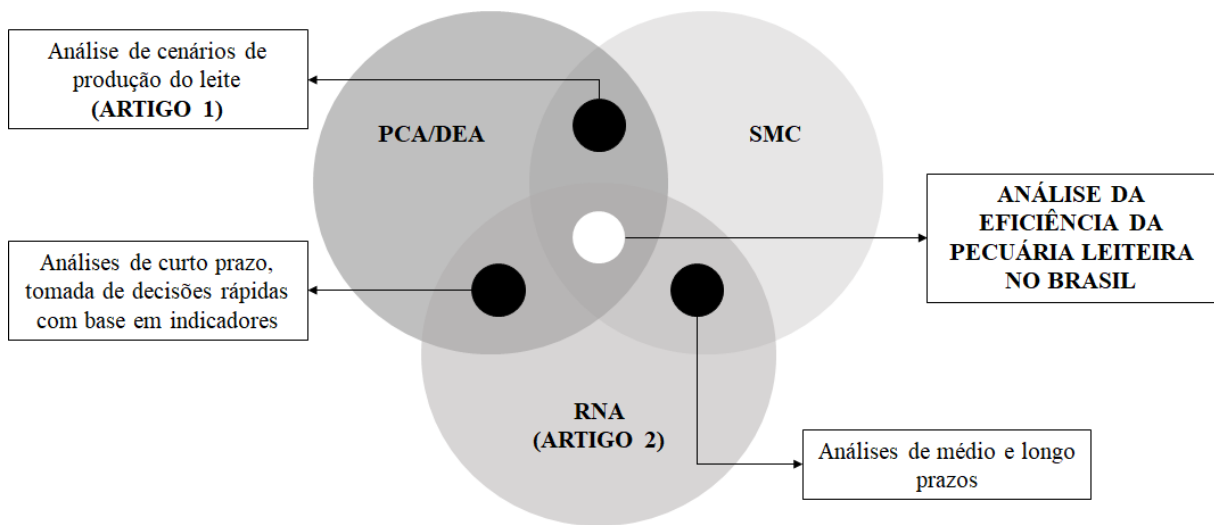
A realização em estágios confere maior rigor, transparência e replicabilidade à pesquisa (Pandey e Pandey, 2021). Além disso, tratando-se de uma pesquisa empírica e com o apoio de diferentes técnicas de análise, o seguimento dos estágios definidos favorece a correta aplicação metodológica. O entendimento da interrelação entre as técnicas também é favorecido. A Figura 15 apresenta uma explicação sucinta desta interrelação.

Figura 15 - Interrelação entre técnicas de análise

(Continua)

Figura 15 - Interrelação entre técnicas de análise

(Conclusão)



Fonte: Do Autor (2024).

Cabe lembrar que se trata de uma pesquisa onde seus resultados foram distribuídos em 2 fases ou artigos. O artigo 1 realizará a aplicação das técnicas PCA/DEA para análise de eficiência de propriedades leiteiras, em seguida este apresentará uma seção dedicada à técnica de Simulação de Monte Carlo a fim de propor um benchmark probabilístico de produção para DMUs ineficientes. A combinação destas técnicas se apoia em estudos já consolidados no âmbito acadêmico com apresentado por Adler e Yazhensky (2010), Chen e Han (2021), e Yaghoubi e Fazli (2021). Já o artigo 2 contemplará a aplicação das Redes Neurais Artificiais para a previsão de preços do leite e identificação dos melhores períodos para relação de trocas (insumo/produto). Por fim, a aplicação de todas as técnicas foi realizada com apoio dos *softwares R-Project 3.2.2 e RStudio 2023.12.0+369*.

A priori, a aplicação da Análise de Componentes Principais ocorreu em um conjunto de 12 variáveis, conforme as classificações de *inputs* e *outputs*, foram selecionadas as que obtiverem os maiores autovetores e, portanto, os maiores índices de correlação, em módulo, a partir das três primeiras componentes principais (CP1, CP2 e CP3). A associação entre as técnicas Análise de Componentes Principais e Análise Envoltória de Dados é útil para as etapas iniciais do estudo em que ocorre a identificação de variáveis originais de análise, assim, a Análise de Componentes Principais permite a redução do volume de variáveis consideradas. Diversas variáveis podem apresentar correlação alta, como, por exemplo, Receita Anual e Capacidade de produção por hectares, ou Quantidade de colaboradores e Área de produção.

Nesse contexto, a PCA pode ser particularmente útil, pois captura a maior parte da variação dos dados nos primeiros componentes principais, reduzindo a redundância.

A Análise Envoltória de Dados por outro lado, foi responsável pela classificação das DMUs como eficientes e ineficientes, bem como se dedicou a apresentação dos intervalos existentes entre o valor atual e alvos para cada variável original de análise. Para tanto, o modelo proposto foi o de *Banker, Charnes e Cooper* (BCC) orientado a output, conforme apresentado em (13).

$$\text{Minimizar } \sum_{i=1}^r v_i x_{i0} - v_0 \quad (\mu, v) \quad (13)$$

Sujeito a:

$$\sum_{j=1}^s \mu_j y_{j0} = 1 \quad (13.1)$$

$$\sum_{j=1}^s \mu_j y_{jk} - \sum_{i=1}^r v_i x_{ik} + v_0 \leq 0, \forall k \quad (13.2)$$

$$\mu_j, v_i > 0 (\varepsilon), \forall i, j \quad (13.3)$$

v_0 sem restrição de sinal.

De acordo com o modelo, as restrições (13.1) e (13.2) garantem a convexidade do modelo e que os produtos gerados não podem ser superiores aos insumos, respectivamente. A restrição (13.3) sugere que os fatores de produção devem ser positivos e não nulos para todas as DMUs consideradas. Em seguida, ao realizar a inserção da Simulação de Monte Carlo no estudo foi viabilizada uma análise holística da pecuária leiteira no Brasil a partir da geração de cenários. Foi utilizado o mesmo conjunto de variáveis originais para a realização das simulações, todavia, estas variáveis determinísticas agora foram consideradas como variáveis aleatórias e, portanto, apresentaram comportamentos regidos por distribuições de probabilidade.

Por fim, a utilização da técnica de Redes Neurais Artificiais complementa o estudo da cadeia produtiva do leite no sentido de proporcionar aos gestores e/ou produtores uma visão mais abrangente de seu negócio, criando oportunidades para o melhor planejamento de sua produção. Isso porque ao combinar as técnicas Análise Envoltória de Dados e Redes Neurais Artificiais haverá um conjunto de informações claras que orientem os produtores de unidades

ineficientes em decisões de curto prazo, seja para a melhoria da eficiência ou comercialização da produção.

REFERÊNCIAS

- ABANE, Juliana Abagsonema; BRENIA, Edward. The relationship between organizational environment antecedents and performance management in local government: evidence from Ghana. **Future Business Journal**, v. 7, n. 1, p. 3, 2021.
- ACHOUR, Brahim *et al.* Image analysis for individual identification and feeding behaviour monitoring of dairy cows based on Convolutional Neural Networks (CNN). **Biosystems Engineering**, v. 198, p. 31-49, 2020.
- ADLER, Nicole; YAZHEMSKY, Ekaterina. Improving discrimination in data envelopment analysis: PCA–DEA or variable reduction. **European Journal of Operational Research**, v. 202, n. 1, p. 273-284, 2010.
- AFTAB, Junaid *et al.* The nexus of management innovation, performance management, and organizational performance in the Pakistani construction industry. **Central European Management Journal**, v. 30, n. 4, p. 2-26, 2022.
- AGROPORTAL. Breve história da produção de leite no mundo. 2020. Disponível em: <https://www.agroportal.pt/breve-historia-da-producao-de-leite-na-mundo/>. Acesso em: 28 fev. 2024.
- AKLILU, Ermias Girma *et al.* Artificial neural network and response surface methodology for modeling and optimization of activation of lactoperoxidase system. **South African Journal of Chemical Engineering**, v. 37, p. 12-22, 2021.
- ALMOHTASEB, Ahmad Ali *et al.* Impact of talent management on organizational performance: The moderating role of an effective performance management system. **International Journal of Business and management**, v. 15, n. 4, p. 11-24, 2020.
- ALMOMANI, Fares. Prediction of biogas production from chemically treated co-digested agricultural waste using artificial neural network. **Fuel**, v. 280, p. 118573, 2020.
- ARVIDSSON SEGERKVIST, Katarina *et al.* Research on environmental, economic, and social sustainability in dairy farming: A systematic mapping of current literature. **Sustainability**, v. 12, n. 14, p. 5502, 2020.
- BA, Shidi *et al.* Meta-analysis of greenhouse gas and ammonia emissions from dairy manure composting. **Biosystems engineering**, v. 193, p. 126-137, 2020.
- BALDIN, Michel *et al.* Integrated decision support systems (IDSS) for dairy farming: A discussion on how to improve their sustained adoption. **Animals**, v. 11, n. 7, p. 2025, 2021.
- BARROS, Murillo Vetroni *et al.* An analysis of Brazilian raw cow milk production systems and environmental product declarations of whole milk. **Journal of Cleaner Production**, v. 367, p. 133067, 2022.
- BEBER, Caetano Luiz; LAKNER, Sebastian; SKEVAS, Ioannis. Organizational forms and technical efficiency of the dairy processing industry in Southern Brazil. **Agricultural and Food Economics**, v. 9, p. 1-22, 2021.

BRAGA, Antônio de Pádua; LUDERMIR, Teresa Bernarda; CARVALHO, André Carlos Ponce de Leon Ferreira de. *Redes neurais artificiais: teoria e aplicações*. 2000.

BRASIER, J. E.; SCHWANKE, A. J.; DEVRIES, T. J. Effect of dairy cow personality traits on their adaptation to an automated milking system following parturition. **Journal of Dairy Science**, 2023.

CABRERA, Victor E. *et al.* Symposium review: Real-time continuous decision making using big data on dairy farms. **Journal of dairy science**, v. 103, n. 4, p. 3856-3866, 2020.

CABRERA, Victor E.; FADUL-PACHECO, Liliana. Future of dairy farming from the Dairy Brain perspective: Data integration, analytics, and applications. **International Dairy Journal**, v. 121, p. 105069, 2021.

CANAL DO LEITE (Brasil). A história do leite e a importância do produtor. 2022. Disponível em: <https://canaldoleite.com/artigos/revendo-a-historia-do-leite/>. Acesso em: 28 fev. 2024.

CARDOSO CONSENTINI, Carlos Eduardo; WILTBANK, Milo Charles; SARTORI, Roberto. Factors that optimize reproductive efficiency in dairy herds with an emphasis on timed artificial insemination programs. **Animals**, v. 11, n. 2, p. 301, 2021.

CARDOSO, F. C.; KALSCHUR, K. F.; DRACKLEY, J. K. Symposium review: Nutrition strategies for improved health, production, and fertility during the transition period. **Journal of dairy science**, v. 103, n. 6, p. 5684-5693, 2020.

CEPEA (Brasil). **Metodologia Grãos e Fibra**. 2024. Disponível em: [https://www.cepea.esalq.usp.br/br/metodologia-graos-fibra-cepea.aspx#:~:text=O%20Custo%20Operacional%20Efetivo%20\(COE\)%20inclui%20todos%20os%20itens%20considerados,obra%2C%20servi%C3%A7os%20terceirizados%2C%20comercializa%C3%A7%C3%A3o%20agr%C3%ADcola](https://www.cepea.esalq.usp.br/br/metodologia-graos-fibra-cepea.aspx#:~:text=O%20Custo%20Operacional%20Efetivo%20(COE)%20inclui%20todos%20os%20itens%20considerados,obra%2C%20servi%C3%A7os%20terceirizados%2C%20comercializa%C3%A7%C3%A3o%20agr%C3%ADcola). Acesso em: 03 jul. 2024.

CHEN, Zikang; HAN, Song. Comparison of dimension reduction methods for DEA under big data via Monte Carlo simulation. **Journal of Management Science and Engineering**, v. 6, n. 4, p. 363-376, 2021.

CIÊNCIA DO LEITE. O leite como alimento básico no mundo e no Brasil. 2023. Disponível em: <https://cienciadoleite.com.br/noticia/5856/o-leite-como-alimento-basico-no-mundo-e-no-brasil>. Acesso em: 28 fev. 2024.

CORTÉS, Antonio *et al.* Pursuing the route to eco-efficiency in dairy production: The case of Galician area. **Journal of Cleaner Production**, v. 285, p. 124861, 2021.

DANIEL, Ben Kei. Reimaging research methodology as data science. **Big data and cognitive computing**, v. 2, n. 1, p. 4, 2018.

DAVIDAVIČIENĖ, Vida. Research methodology: An introduction. **Modernizing the Academic Teaching and Research Environment: Methodologies and Cases in Business Research**, p. 1-23, 2018.

DE LAUWERE, Carolien *et al.* Understanding decision-making of dairy farmers with regard to participation in a dairy health programme. **Livestock Science**, v. 239, p. 104061, 2020.

DE LIMA SANTOS, Girlene Cordeiro *et al.* Palm oil cake in milk production and quality of dairy cows: Systematic review, meta-analysis and principal component analysis. **Livestock Science**, v. 254, p. 104760, 2021.

DELIOS, Andrew *et al.* Reconsidering, refashioning, and reconceptualizing research methodology in international business. **Journal of World Business**, v. 58, n. 6, p. 101488, 2023.

DIMOV, Dimo *et al.* Factors determining the choice of bedding for freestall housing system in dairy cows farming-A review. **Journal of Central European Agriculture**, v. 22, n. 1, p. 1-13, 2021.

DITTRICH, I. *et al.* Combining multivariate cumulative sum control charts with principal component analysis and partial least squares model to detect sickness behaviour in dairy cattle. **Computers and Electronics in Agriculture**, v. 186, p. 106209, 2021.

DUTTON-REGESTER, Kate J. *et al.* Lameness in dairy cows: Farmer perceptions and automated detection technology. **Journal of Dairy Research**, v. 87, n. S1, p. 67-71, 2020.

EDWARDS, J. P. *et al.* Technologies and milking practices that reduce hours of work and increase flexibility through milking efficiency in pasture-based dairy farm systems. **Journal of dairy science**, v. 103, n. 8, p. 7172-7179, 2020.

ERICKSON, Peter S.; KALSCHEUR, Kenneth F. Nutrition and feeding of dairy cattle. In: **Animal Agriculture**. Academic Press, 2020. p. 157-180.

FEIL, Alexandre André *et al.* Sustainability performance of small and medium dairy enterprises in Brazil. **Sustainable Production and Consumption**, v. 39, p. 301-310, 2023.

FEYISSA, Abraham Abera *et al.* Unlocking the potential of smallholder dairy farm: Evidence from the central highland of Ethiopia. **Journal of Agriculture and Food Research**, v. 11, p. 100467, 2023.

FROLDI, Federico *et al.* Environmental impacts of cow's milk in Northern Italy: Effects of farming performance. **Journal of Cleaner Production**, v. 363, p. 132600, 2022.

FUENTES, Sigfredo *et al.* Artificial intelligence applied to a robotic dairy farm to model milk productivity and quality based on cow data and daily environmental parameters. **Sensors**, v. 20, n. 10, p. 2975, 2020.

GARVEY, Mary. Lameness in dairy cow herds: disease aetiology, prevention and management. **Dairy**, v. 3, n. 1, p. 199-210, 2022.

GIORDANO, J. O. *et al.* Symposium review: Use of multiple biological, management, and performance data for the design of targeted reproductive management strategies for dairy cows. **Journal of Dairy Science**, v. 105, n. 5, p. 4669-4678, 2022.

GIVENS, D. I. MILK Symposium review: The importance of milk and dairy foods in the diets of infants, adolescents, pregnant women, adults, and the elderly. **Journal of dairy science**, v. 103, n. 11, p. 9681-9699, 2020.

GODFREY, Sosheel Solomon; IP, Ryan HL; NORDBLOM, Thomas Lee. Risk analysis of Australia's Victorian dairy farms using multivariate copulae. **Journal of Agricultural and Applied Economics**, v. 54, n. 1, p. 72-92, 2022.

GORI MAIA, Alexandre *et al.* Climate resilience programmes and technical efficiency: evidence from the smallholder dairy farmers in the Brazilian semi-arid region. **Climate and Development**, v. 14, n. 3, p. 197-207, 2022.

GUZMÁN-LUNA, Paola *et al.* Analysing the interaction between the dairy sector and climate change from a life cycle perspective: A review. **Trends in Food Science & Technology**, v. 126, p. 168-179, 2022.

HAYKIN, Simon. Redes neurais: princípios e prática. Bookman Editora, 2001.

HOLLY, Michael A. *et al.* Management characteristics of Pennsylvania dairy farms. **Applied Animal Science**, v. 35, n. 3, p. 325-338, 2019.

HOSSEINZADEH LOTFI, Farhad *et al.* Data Envelopment Analysis. In: **Supply Chain Performance Evaluation: Application of Data Envelopment Analysis**. Cham: Springer International Publishing, 2023. p. 179-241.

IBGE. Rebanhos e valor dos principais produtos de origem animal foram recordes em 2022. 2023. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/37937-rebanhos-e-valor-dos-principais-produto-de-origem-animal-foram-recordes-em-2022#:~:text=A%20produ%C3%A7%C3%A3o%20de%20leite%20de,milh%C3%B5es%20de%20cabe%C3%A7..> Acesso em: 28 fev. 2024.

ILYAS, Hafiz Muhammad Abrar *et al.* Energy efficiency outlook of New Zealand dairy farming systems: An application of data envelopment analysis (DEA) approach. **Energies**, v. 13, n. 1, p. 251, 2020.

JACKSON, Amy *et al.* Understanding public preferences for different dairy farming systems using a mixed-methods approach. **Journal of Dairy Science**, v. 105, n. 9, p. 7492-7512, 2022.

JEBARI, Asma *et al.* Effect of dairy cattle production systems on sustaining soil organic carbon storage in grasslands of northern Spain. **Regional Environmental Change**, v. 22, n. 2, p. 67, 2022.

Jl, Boyu *et al.* Modelling of heat stress in a robotic dairy farm. Part 1: Thermal comfort indices as the indicators of production loss. **Biosystems Engineering**, v. 199, p. 27-42, 2020.

JULIANSYAH, Arief; SULISTYOWATI, Endang; BADRUDIN, Redy. Strategy Development of Dairy Farms by Using SWOT Analysis in Province Bengkulu. **Journal of Agri Socio Economics and Business**, v. 4, n. 02, p. 181-192, 2022.

KADAK, Tarmo; LAITINEN, Erkki K. How different types of performance management systems affect organizational performance?. **Measuring Business Excellence**, v. 25, n. 3, p. 315-327, 2021.

KECELI, Ali Seydi *et al.* Development of a recurrent neural networks-based calving prediction model using activity and behavioral data. **Computers and Electronics in Agriculture**, v. 170, p. 105285, 2020.

KHALTAR, Odkhuu; MOON, M. Jae. Effects of ethics and performance management on organizational performance in the public sector. **Public Integrity**, v. 22, n. 4, p. 372-394, 2020.

KOURIATI, Asimina *et al.* The Impact of Data Envelopment Analysis on Effective Management of Inputs: The Case of Farms Located in the Regional Unit of Pieria. **Agronomy**, v. 13, n. 8, p. 2109, 2023.

KOVÁCS, Krisztián; SZŰCS, István. Exploring efficiency reserves in Hungarian milk production. **Studies in Agricultural Economics**, v. 122, n. 1, p. 37-43, 2020.

KRISHNA, N. Leela *et al.* Involvement of women in decision making of different dairy farm activities. **Indian Journal of Extension Education**, v. 57, n. 1, p. 124-129, 2021.

LAU, Samantha *et al.* Development of a Monte Carlo simulation model to predict pasteurized fluid milk spoilage due to post-pasteurization contamination with gram-negative bacteria. **Journal of Dairy Science**, v. 105, n. 3, p. 1978-1998, 2022.

LEITÃO, Fabrício Oliveira; PAIVA, Ely Laureano; THOMÉ, Karim Marini. Agribusiness capabilities and performance: a systematic literature review and research agenda. **British Food Journal**, v. 126, n. 2, p. 595-622, 2024.

LEITGEB, Friedrich *et al.* Comparing the ecological sustainability performance of organic farms and conventional production in Austria using the SMART farm tool and Monte Carlo simulation. **Organic Agriculture**, p. 1-19, 2023.

LISEUNE, Arno *et al.* Predicting the milk yield curve of dairy cows in the subsequent lactation period using deep learning. **Computers and Electronics in Agriculture**, v. 180, p. 105904, 2021.

LIU, Shenhe *et al.* Transcriptome analysis reveals potential regulatory genes related to heat tolerance in holstein dairy cattle. **Genes**, v. 11, n. 1, p. 68, 2020.

MAINA, Florence *et al.* Factors influencing economic efficiency of milk production among small-scale dairy farms in Mukurweini, Nyeri County, Kenya. **Tropical animal health and production**, v. 52, p. 533-539, 2020.

MAPA (Brasil). **Mapa do Leite**: políticas públicas e privadas para o leite. Políticas públicas e privadas para o leite. 2024. Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/producao-animal/mapa-do-leite>. Acesso em: 03 jul. 2024.

MAPA (Brasil). **Pequeno e Médio Produtor**. 2024. Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/producao-animal/mapa-do-leite/pequeno-e-medio-produtor>. Acesso em: 03 jul. 2024.

MARIYONO, Joko. Improvement of economic and sustainability performance of agribusiness management using ecological technologies in Indonesia. **International Journal of Productivity and Performance Management**, v. 69, n. 5, p. 989-1008, 2020.

MARTINELLI, Raiane Real *et al.* Horizontal collaborations and the competitiveness of dairy farmers in Brazil. **Journal of Co-operative Organization and Management**, v. 10, n. 2, p. 100183, 2022.

MASELLO, M. *et al.* Effect of reproductive management programs for first service on replacement dairy heifer economics. **Journal of Dairy Science**, v. 104, n. 1, p. 471-485, 2021.

MIGDADI, Mahmoud Mohammad. Knowledge management processes, innovation capability and organizational performance. **International Journal of Productivity and Performance Management**, v. 71, n. 1, p. 182-210, 2022.

MILKPOINT (Brasil). **Free stall: mitos e verdades sobre o sistema**. 2024. Disponível em: <https://www.milkpoint.com.br/colunas/educapoint/mitos-e-verdades-sobre-o-free-stall-215540/>. Acesso em: 03 jul. 2024.

NAQVI, S. Ali *et al.* Mastitis detection with recurrent neural networks in farms using automated milking systems. **Computers and Electronics in Agriculture**, v. 192, p. 106618, 2022.

NATH, Prafulla Kumar. Collective Dairy Farming, Women Empowerment and Social Inclusion: A Village-Level Study from Bihar, India. **Global Business Review**, p. 09721509221121701, 2022.

NDAMBI, Asaah *et al.* **Impact of fodder management on dairy farm performance in Kenya**. Wageningen Livestock Research, 2020.

NGUYEN, Oanh TK *et al.* The moderating effect of perceived environmental uncertainty and task uncertainty on the relationship between performance management system practices and organizational performance: evidence from Vietnam. **Production Planning & Control**, v. 34, n. 5, p. 423-441, 2023.

NYOKABI, Simon *et al.* Milk quality and hygiene: Knowledge, attitudes and practices of smallholder dairy farmers in central Kenya. **Food Control**, v. 130, p. 108303, 2021.

OEHM, Andreas W. *et al.* Multinomial logistic regression based on neural networks reveals inherent differences among dairy farms depending on the differential exposure to *Fasciola hepatica* and *Ostertagia ostertagi*. **International Journal for Parasitology**, 2023.

OĞUZ, Cennet; YENER, Aysun. The use of energy in milk production; a case study from Konya province of Turkey. **Energy**, v. 183, p. 142-148, 2019.

OJO, Oluwaseun Mercy *et al.* Unraveling the impact of variable external input use on the cost efficiency of dairy farms in Europe. **Environmental and Sustainability Indicators**, v. 8, p. 100076, 2020.

OKELLO, Dickson Otieno; LUTTAH, Fahad Juma. Effects of market orientation on farmer resilience and dairy farm performance in emerging economy. **Cogent Business & Management**, v. 9, n. 1, p. 2010481, 2022.

PANDEY, Prabhat; PANDEY, Meenu Mishra. Research methodology tools and techniques. **Bridge Center**, 2021.

PAVLOV, Andrey; MICHELI, Pietro. Rethinking organizational performance management: a complexity theory perspective. **International journal of operations & production management**, v. 43, n. 6, p. 899-915, 2022.

PEDOLIN, Dario *et al.* Farm diversity impacts on food production, income generation and environmental preservation: The Swiss case. **Journal of Cleaner Production**, v. 388, p. 135851, 2023.

PINHEIRO, J. S. *et al.* Production costs, economic viability, and risks associated with compost bedded pack, freestall, and drylot systems in dairy farms. **Animal**, v. 15, n. 12, p. 100404, 2021.

PUUPPONEN, Antti *et al.* Finnish dairy farmers' perceptions of justice in the transition to carbon-neutral farming. **Journal of Rural Studies**, v. 90, p. 104-112, 2022.

RASMUSSEN, Philip *et al.* Economic losses due to Johne's disease (paratuberculosis) in dairy cattle. **Journal of dairy science**, v. 104, n. 3, p. 3123-3143, 2021.

ROMANIUK, Waław *et al.* Biomass energy technologies from innovative dairy farming systems. **Processes**, v. 9, n. 2, p. 335, 2021.

RUVIARO, Clandio Favarini *et al.* Life cycle cost analysis of dairy production systems in Southern Brazil. **Science of the Total Environment**, v. 741, p. 140273, 2020.

SALINAS-MARTÍNEZ, Jesús Armando *et al.* Cost analysis and economic optimization of small-scale dairy production systems in Mexico. **Livestock Science**, v. 237, p. 104028, 2020.

SCHIANO, A. N. *et al.* Consumer perception of the sustainability of dairy products and plant-based dairy alternatives. **Journal of Dairy Science**, v. 103, n. 12, p. 11228-11243, 2020.

SCHUETZ, Christoph G.; SCHREFL, Michael. Conceptualizing analytics: an overview of business intelligence and analytics from a conceptual-modeling perspective. **Digital Transformation: Core Technologies and Emerging Topics from a Computer Science Perspective**, p. 311-336, 2023.

SEFEEDPARI, Paria; SHOKOOHI, Zeinab; PISHGAR-KOMLEH, Seyyed Hassan. Dynamic energy efficiency assessment of dairy farming system in Iran: Application of window data envelopment analysis. **Journal of Cleaner Production**, v. 275, p. 124178, 2020.

SIAPAKAS, Stavros *et al.* Identification of efficient dairy farms in Greece based on home grown feedstuffs, using the Data Envelopment Analysis method. **Livestock Science**, v. 222, p. 14-20, 2019.

SILVA, I. N. Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas. Fundamentos Teóricos e Aspectos Práticos, Editora : Artliber; 2ª edição, 2016.

SILVEIRA, Robson Mateus Freitas *et al.* Diversity in smallholder dairy production systems in the Brazilian semiarid region: farm typologies and characteristics of raw milk and water used in milking. **Journal of Arid Environments**, v. 203, p. 104774, 2022.

SILVI, Rebeca *et al.* Adoption of precision technologies by Brazilian dairy farms: The farmer's perception. **Animals**, v. 11, n. 12, p. 3488, 2021.

SIQUEIRA, Tiago Teixeira da Silva *et al.* Organizational forms and agri-environmental practices: The case of Brazilian dairy farms. **Sustainability**, v. 13, n. 7, p. 3762, 2021.

SIVASUBRAMANIAN, K.; ADARSH, Roopa; KRISHNAMURTHY, Anu. Economic Empowerment of Women Through Household Dairy Farming in Rural India. In: **Information and Communication Technology in Technical and Vocational Education and Training for Sustainable and Equal Opportunity: Education, Sustainability and Women Empowerment**. Singapore: Springer Nature Singapore, 2024. p. 105-115.

SLOB, Naftali; CATAL, Cagatay; KASSAHUN, Ayalew. Application of machine learning to improve dairy farm management: A systematic literature review. **Preventive Veterinary Medicine**, v. 187, p. 105237, 2021.

SOTERIADES, Andreas D. *et al.* Maintaining production while reducing local and global environmental emissions in dairy farming. **Journal of Environmental Management**, v. 272, p. 111054, 2020.

TALUKDER, Byomkesh *et al.* Multi-indicator supply chain management framework for food convergent innovation in the dairy business. **Sustainable Futures**, v. 3, p. 100045, 2021.

TASSINARI, Patrizia *et al.* A computer vision approach based on deep learning for the detection of dairy cows in *free stall* barn. **Computers and Electronics in Agriculture**, v. 182, p. 106030, 2021.

THOMAS, C. George. **Research methodology and scientific writing**. Thrissur: Springer, 2021.

TIAN, Fuyang *et al.* An efficient multi-task convolutional neural network for dairy farm object detection and segmentation. **Computers and Electronics in Agriculture**, v. 211, p. 108000, 2023.

- UREÑA-ESPAILLAT, Hayrold José et al. Knowledge and innovation management in agribusiness: A study in the Dominican Republic. **Business Strategy and the Environment**, v. 32, n. 4, p. 2008-2021, 2023.
- VAN AKEN, Armin et al. Udder health, veterinary costs, and antibiotic usage in *free stall* compared with tie stall dairy housing systems: An optimized matching approach in Switzerland. **Research in Veterinary Science**, v. 152, p. 333-353, 2022.
- VAN EERDENBURG, Frank JCM; RUUD, Lars Erik. Design of *free stalls* for dairy herds: A review. **Ruminants**, v. 1, n. 1, p. 1-22, 2021.
- VANHUYSE, Fedra; BAILEY, Alison; TRANTER, Richard. Management practices and the financial performance of farms. **Agricultural Finance Review**, v. 81, n. 3, p. 415-429, 2021.
- VAN WAEYENBERG, Thomas; PECCEI, Riccardo; DECRAMER, Adeliën. Performance management and teacher performance: the role of affective organizational commitment and exhaustion. **The International Journal of Human Resource Management**, v. 33, n. 4, p. 623-646, 2022.
- VERRAES, Claire *et al.* Microbiological safety and quality aspects of the short supply chain: SWOT analysis of the belgian case study. **British Food Journal**, v. 117, n. 9, p. 2250-2264, 2015.
- VILELA, Duarte *et al.* A evolução do leite no Brasil em cinco décadas. **Revista de Política Agrícola**, v. 26, n. 1, p. 5-24, 2017.
- WAIRIMU, Edith *et al.* Characterization of dairy innovations in selected milksheds in Kenya using a categorical principal component analysis. **Tropical Animal Health and Production**, v. 53, p. 1-12, 2021.
- WANKAR, Alok K.; RINDHE, Sandeep N.; DOJAD, Nandkumar S. Heat stress in dairy animals and current milk production trends, economics, and future perspectives: the global scenario. **Tropical Animal Health and Production**, v. 53, n. 1, p. 70, 2021.
- YAGHOUBI, Ali; FAZLI, Safar. Proposing a Model to Forecast the Efficiency of Bank Branches under Uncertainty Conditions based on SDEA-PCA Approach and Monte Carlo Simulation. **Modern Research in Decision Making**, v. 6, n. 4, p. 1-33, 2021.
- YAPICIOĞLU, Pelin; YEŞILNACAR, Mehmet Irfan. Energy cost assessment of a dairy industry wastewater treatment plant. **Environmental Monitoring and Assessment**, v. 192, p. 1-17, 2020.
- YU, Zetian *et al.* Production Efficiency of Raw Milk and Its Determinants: Application of Combining Data Envelopment Analysis and Stochastic Frontier Analysis. **Agriculture**, v. 13, n. 2, p. 370, 2023.
- ZANIN, Antônio *et al.* Driving sustainability in dairy farming from a TBL perspective: Insights from a case study in the West Region of Santa Catarina, Brazil. **Sustainability**, v. 12, n. 15, p. 6038, 2020.

ZHANG, Junyan *et al.* Identifying key pathways in manure and sewage management of dairy farming based on a quantitative typology: A case study in China. **Science of the Total Environment**, v. 760, p. 143326, 2021.

ZHENG, Zhiyang *et al.* Cows' legs tracking and lameness detection in dairy cattle using video analysis and Siamese neural networks. **Computers and Electronics in Agriculture**, v. 205, p. 107618, 2023.

SEGUNDA PARTE - ARTIGOS

Nesta parte são expostos os artigos resultantes deste estudo, sendo eles: Artigo 1 - Benchmarks probabilísticos aumentam a eficiência da pecuária leiteira; Artigo 2 - Previsão de oscilações no preço do leite promove a permanência de pequenos e médios produtores no setor.

ARTIGO 1 – BENCHMARKS PROBABILÍSTICOS AUMENTAM A EFICIÊNCIA DA PECUÁRIA LEITEIRA

Resumo

A pecuária leiteira corresponde a um setor amplo que contribui para a geração de renda e empregos a diferentes classes populacionais. Todavia, este setor tem sido impactado pela alta volatilidade de mercado, decorrente de aspectos de consumo, questões climáticas, sazonalidade de preços, entre outros. Tais aspectos acabam aumentando as distorções existentes no setor e potencializa a divergência de realidade entre pequenos, médios e grandes produtores. Por isso, o objetivo deste estudo foi avaliar o desempenho das regiões produtoras de leite no Brasil em 2022 a partir da utilização das técnicas Análise de Componentes Principais (PCA), Análise Envoltória de Dados (DEA) e Simulação de Monte Carlo (SMC). Este estudo foi construído nos moldes de uma pesquisa empírica, com abordagem quantitativa e lógica indutiva. Os resultados revelaram que apenas 35% dos produtores obtiveram eficiência técnica pura máxima, sendo que cerca de 91% do total de produtores apresenta áreas de produção inferior a 100 hectares. A etapa probabilística forneceu insights valiosos, a partir dos melhores ajustes das variáveis do modelo com base nas funções Log-Logística, Pearson e Log-Normal. Neste sentido, a proposição de benchmarks probabilísticos contribui para o aumento da competitividade do setor, potencializando a busca por melhorias de qualidade do leite, manejo do rebanho e infraestrutura bem como pode auxiliar na otimização do consumo de recursos nas propriedades leiteiras.

Palavras-chave: Gestão de desempenho; Análise Envoltória de Dados; Simulação de Monte Carlo; pecuária; leite;

1 INTRODUÇÃO

A pecuária leiteira, em nível global, desempenha importantes funções relacionadas a geração de saúde, estabilidade econômica e desenvolvimento sustentável (Cabrera; Fadul-Pacheco, 2021). No âmbito nutricional, o leite é vital para o desenvolvimento de crianças, pois fornece uma base rica em proteínas, cálcio e vitaminas que favorecem o bom desempenho da saúde pública (Givens *et al.*, 2020). Economicamente, a produção de leite contribui para a empregabilidade da população, impulsionando o desenvolvimento rural e a sustentabilidade econômica (Wankar; Rindhe; Doijad, 2021). Questões relacionadas à segurança alimentar e redução da pobreza também contemplam benefícios alcançados pela produção do leite, pois trata-se de um alimento de alto consumo, que sustenta uma vasta cadeia de valor desde a produção à distribuição de produtos lácteos (Arvidsson Segerkvist *et al.*, 2020).

A produção mais sustentável também satisfaz um dos objetivos da pecuária de leite moderna (Siqueira *et al.*, 2021). Trabalhar mecanismos que garantam uma produção do leite com a geração de menores impactos ao meio ambiente torna-se uma tarefa cada vez mais importante (Feil *et al.*, 2023). Aliás, acentua-se aqui o impacto negativo promovido pelas mudanças climáticas no contexto de produção do leite (Arvidsson Segerkvist *et al.*, 2020). Isso porque a alteração do ciclo de chuvas e períodos de seca extensos ocasionam a queda de produção de insumos para alimentação animal e, portanto, reduz a produtividade dos animais (Feil *et al.*, 2023).

No contexto da análise de desempenho, os custos de produção representam um aspecto fundamental para a gestão da eficiência das propriedades leiteiras (Maina *et al.* 2020). Muitos produtores acabam se desvinculando do setor em razão de altos custos de produção. Além disso, o acesso ao crédito por pequenos e médios produtores tem sido um desafio socioeconômico recorrente (Wankar; Rindhe; Doijad, 2021). Apesar do crescimento do setor, este ainda possui uma lacuna para desenvolvimento infraestrutural (Feil *et al.*, 2023). Sendo assim, criar condições para que pequenos e médios produtores também se sobressaiam neste setor é essencial para o alcance de melhores preços e vantagem competitiva (Maina *et al.* 2020).

O cenário de produção de leite ainda se caracteriza pela formação de pequenas barreiras de entrada, que favorecem a entrada de pequenos e médios produtores no setor (Feil *et al.*, 2023). Trata-se de um problema no âmbito da eficiência de produção, pois muitos destes produtores ao iniciar suas atividades no setor não apresentam um nível de instrução adequado para a gestão de recursos e qualidade de insumos e produtos (Ojo *et al.*, 2020). Logo, destaca-

se a carência de programas de apoio a estas classes de produtores que se comportam de forma vulnerável mediante as volatilidades do mercado (Siafakas *et al.*, 2019).

O acesso limitado ao crédito e financiamento agrava a desigualdade entre pequenos, médios e grandes produtores (Ruviano *et al.*, 2020). Estes recursos são vitais para que pequenos e médios produtores possam se manter na atividade a partir de investimentos em infraestrutura, tecnologia e insumos (Maina *et al.* 2020). A falta de conhecimento e treinamento sobre boas práticas de manejo, alimentação e saúde animal associada a problemas de infraestrutura básica podem reduzir a qualidade do leite produzido, bem como a ocasionar perdas de eficiência e produtividade das propriedades leiteiras (Kouriati *et al.*, 2023). Diante destes impasses, este estudo avança sua investigação no contexto de produção de leite no Brasil apresentando algumas questões norteadoras de pesquisa, a saber: Quais os principais indicadores que afetam o desempenho das propriedades leiteiras amostradas? Como a mensuração dos escores de eficiência combinada à técnica de simulação pode contribuir para o aumento do desempenho de propriedades ineficientes?

Estudos tem sido realizados no setor da pecuária leiteira no âmbito da gestão de desempenho, como apresentado por Dittrich *et al.* (2021), os autores extraíram informações de variáveis comportamentais e parâmetros de desempenho de vacas leiteiras em uma propriedade da Alemanha. Entretanto, o estudo não possui caráter comparativo entre diferentes propriedades leiteiras e não avança na previsão de cenários de eficiência de produção. Kovács e Szűcs (2020) estimaram a eficiência de pequenos, médios e grandes produtores da Hungria. Todavia, o estudo se dedicou apenas à apresentação de resultados estatísticos descritivos e de eficiência técnica pura. Os autores não discutiram sobre variáveis de interesse e alvos de eficiência.

Quanto a simulação de cenários, Godfrey, Ip e Nordblom (2022) realizou análises comparativas para identificação de risco e viabilidade financeira de três regiões da Austrália. Já Masello *et al.* (2021) avaliaram o efeito de programas de manejo reprodutivo na economia de vacas leiteiras de reposição. No entanto, estes autores em ambos os casos não desenvolveram uma triangulação metodológica com técnicas de mensuração de eficiência. Este autores também não avançaram suas discussões para análises mais refinadas de sensibilidade e meta.

A utilização das técnicas de apoio a tomada de decisão, Análise de Componentes Principais (PCA), Análise Envoltória de Dados (DEA) e Simulação de Monte Carlo (SMC), revelam o caráter multidisciplinar deste estudo e o seu potencial de triangulação entre diferentes abordagens metodológicas. Acentua-se aqui a complementariedade entre as técnicas PCA e DEA que promovem a redução da dimensionalidade dos dados, a eliminação de redundâncias e a simplificação da análise a partir de uma medida objetiva e comparativa de desempenho

pautada em múltiplos inputs e outputs (Chen; Han, 2021; Yaghoubi; Fazli, 2021). A Simulação de Monte Carlo ao ser incorporada neste processo de análise de desempenho promove avanços na modelagem de variáveis aleatórias e previsão de cenários de propriedades ineficientes, fornecendo insights para o alcance de eficiência nestes casos.

As novidades e contribuições deste estudo contemplam a proposição de um modelo de análise de desempenho da pecuária leiteira. Nesta perspectiva busca-se contribuir com a geração de insights no âmbito da gestão de desempenho para todas as classes de produtores, de modo a reduzir a desigualdade existente entre pequenos, médios e grandes produtores. As implicações políticas do estudo correspondem ao desenvolvimento de políticas públicas de apoio a produção leiteira, ao planejamento estratégico eficiente e alocação correta de recursos, redução de desigualdade no setor, a promoção da segurança alimentar e economia rural, bem como o próprio monitoramento e avaliação de políticas agrícolas. Neste contexto, o objetivo geral deste estudo foi avaliar o desempenho das regiões produtoras de leite no Brasil em 2022 a partir da utilização das técnicas PCA, DEA e SMC.

2 METODOLOGIA

Este estudo contempla uma pesquisa empírica, com abordagem quantitativa e lógica indutiva. A técnica Análise de Componentes Principais foi utilizada como técnica de pré-processamento de dados, para a seleção das variáveis de análise. Já a técnica Análise Envoltória de Dados foi utilizada para subsidiar a análise de eficiência técnica pura das propriedades leiteiras amostradas. A Tabela 1 representa o conjunto de indicadores considerados para a avaliação de desempenho das propriedades leiteiras no Brasil.

Tabela 1 - Indicadores para avaliação de desempenho de propriedades leiteiras

Dimensão	Indicador	Unidade	Classificação	Descrição
Receita	PPP	R\$	Output	Preço pago ao produtor
Produção	QLV	L	Input	Quantidade de leite vendido
Receita	RL	R\$	Output	Receita do leite
Produção	QLP	L	Output	Quantidade de leite produzido
Custos Operacionais	CEMV	R\$	Input	Gastos com concentrado e mineral para vaca
Custos Operacionais	AL	R\$	Input	Gastos com aleitamento
Custos Operacionais	MED	%	Input	Gastos com medicamentos e curativos
Custos Operacionais	OR	R\$	Input	Gastos com materiais e manutenção de ordenha
Custos Operacionais	EC	R\$	Input	Gastos com energia e combustíveis
Custos Operacionais	COEL	R\$/L	Input	Custo Operacional Efetivo por litro
Produção	PD	L	Output	Produção diária total
Produção	VL	Quantidade	Input	Número de vacas em lactação

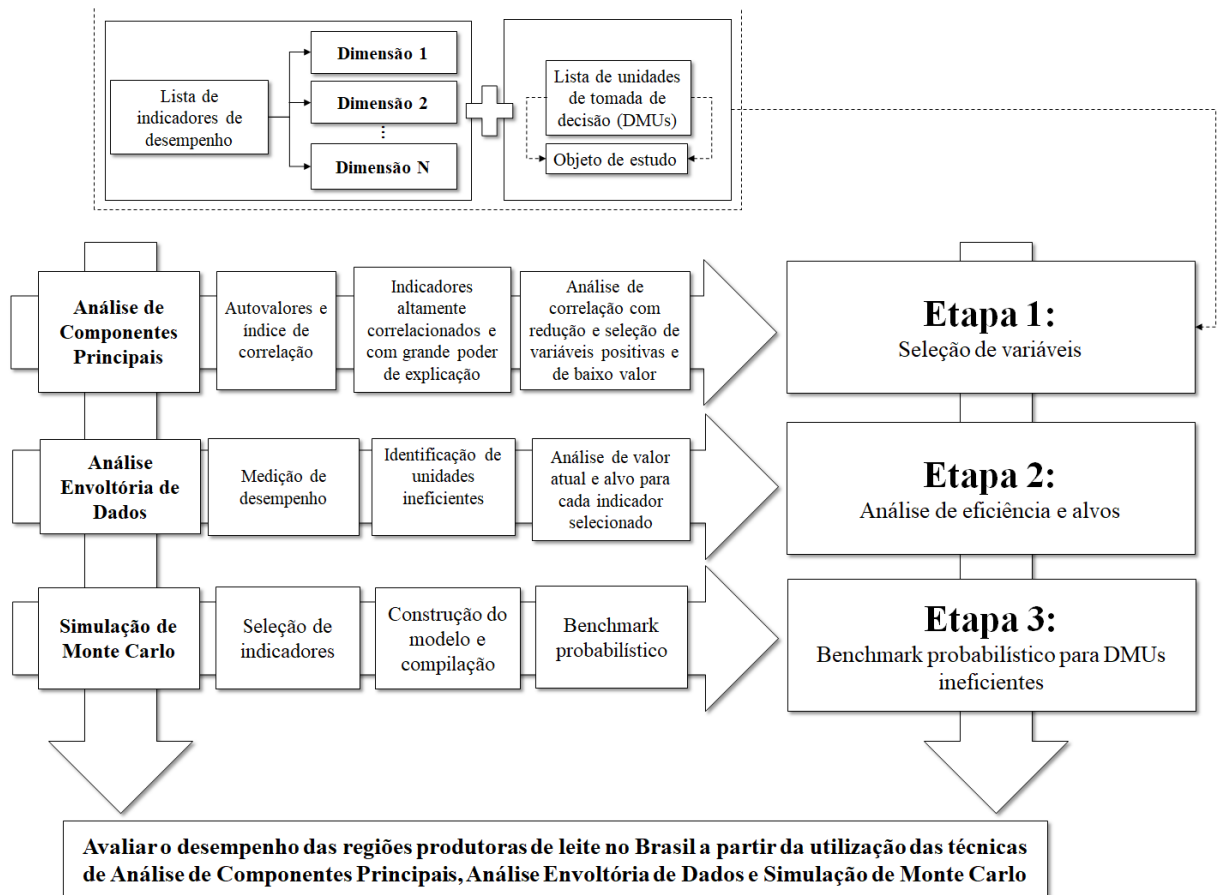
Fonte: Do autor (2024).

Trata-se de 12 indicadores obtidos a partir do acesso aos dados secundários da empresa analisada para 57 produtores correspondentes ao ano de 2022. Este período de análise foi definido mediante a integralidade dos dados amostrados. Logo, os produtores considerados representam satisfatoriamente as regiões atendidas pela empresa. Tais regiões abrangem 18 dos estados brasileiros, a saber, Rondônia, Pará, Maranhão, Ceará, Piauí, Tocantins, Sergipe, Bahia, Mato Grosso, Mato Grosso do Sul, Goiás, Minas Gerais, Espírito Santo, São Paulo, Rio de Janeiro, Paraná, Santa Catarina e Rio Grande do Sul. Pautando-se no objetivo deste estudo a Figura 1 representa o modelo de gestão de desempenho proposto para a avaliação da eficiência da pecuária leiteira no Brasil.

Figura 1 - Modelo proposto para avaliação da eficiência da pecuária leiteira no Brasil

(Continua)

(Conclusão)



Fonte: Do autor (2024).

De acordo com a Figura 1, o modelo de análise de desempenho proposto contemplou três etapas, a saber, Seleção de variáveis, Análise de eficiência e alvos, e Proposição e análise de cenários. Trata-se de um modelo genérico que visa proporcionar avanços teóricos e práticos na área de gestão de desempenho aplicada a pecuária leiteira no Brasil. Neste sentido, este estudo avança na descrição das etapas de pesquisa, que são interdependentes e complementares:

1. **Primeira etapa:** Aplicação da Análise de Componentes Principais e proposição de índices globais de desempenho para a gestão das propriedades leiteiras.
2. **Segunda etapa:** Aplicação da técnica de Análise Envoltória de Dados.
3. **Terceira etapa:** Aplicação da técnica de Simulação de Monte Carlo para melhoria de eficiência de propriedades ineficientes.

No âmbito da análise de desempenho das propriedades leiteiras, o modelo proposto contempla a definição de uma lista de indicadores de desempenho a ser construída nos

momentos iniciais do estudo. Os indicadores pertencem a dimensões de desempenho que podem variar de 1 a N categorias, de acordo com os dados amostrados. Acentua-se aqui a importância da primeira etapa deste modelo para conferir maior rigor e consistência aos processos de seleção de variáveis originais e unidades de tomada de decisão.

A técnica de Análise de Componentes Principais, referente a etapa 1, pode ser descrita algebricamente pela equação (1) adaptada de Ferreira (2011) e Johnson e Wichern (2007), e pautada nas contribuições de Tadayon e Liu (1993) e Hosamani *et al.* (1996). Deste modo, Y_i corresponde à componente principal, onde o número de variáveis originais contempladas deve ser inferior ou igual ao número de componentes principais (Sharma *et al.*, 2011; Sinha *et al.*, 2011), logo, $Y_i = 1, 2, \dots, p$; já e refere-se aos autovetores ($e = 1, 2, \dots, p$) e X às variáveis originais selecionadas ($X = 1, 2, \dots, p$).

$$Y_i = e_{i1}X_1 + e_{i2}X_2 + \dots + e_{ip}X_p \quad (1)$$

Considerando a realização da etapa 1 deste modelo de análise de desempenho para as 12 variáveis originais da Tabela 1, conforme a classificação de inputs e outputs, foram selecionadas as que obtiveram maiores autovetores e , portanto, maior correlação, considerando as três primeiras componentes principais (PC1, PC2 e PC3). A utilização deste número de componentes se justifica pela explicação do maior percentual de variância total dos dados (Granato *et al.*, 2018).

A segunda etapa do modelo de análise de desempenho ocorreu mediante a aplicação da técnica de Análise Envoltória de Dados. Como modelo de análise, este estudo optou pela utilização do modelo de retornos variáveis de escala, ou seja, o modelo BCC (Banker, Charnes, Cooper) orientado a output. A equação (2) representa a função objetivo do modelo em questão e as equações (2.1), (2.2) e (2.3) suas respectivas restrições adaptadas de Cooper *et al.* (2011).

$$\text{Minimizar } \sum_{i=1}^r v_i x_{i0} - v_0 \quad (\mu, v) \quad (2)$$

Sujeito a:

$$\sum_{j=1}^s \mu_j y_{j0} = 1 \quad (2.1)$$

$$\sum_{j=1}^s \mu_j y_{jk} - \sum_{i=1}^r v_i x_{ik} + v_0 \leq 0, \forall k \quad (2.2)$$

$$\mu_j, v_i > 0 (\varepsilon), \forall i, j \quad (2.3)$$

v_0 sem restrição de sinal.

A equação (2) satisfaz a função objetivo do modelo, na qual preza-se pela minimização da soma ponderada de inputs. A equação (2.1) corresponde a restrição de normalização que assegura que os pesos dos outputs μ_j para a DMU sob avaliação são normalizados de forma que a soma ponderada dos outputs seja igual a 1. A equação (2.2), conhecida como restrição de eficiência, assegura que nenhuma DMU seja considerada mais eficiente do que a DMU em avaliação. Logo, y_{jk} e x_{ik} correspondem aos outputs e inputs da DMU k , respectivamente. A equação (2.3) contempla a restrição de positividade que indica que todos os pesos atribuídos aos inputs e outputs sejam positivos. A constante v_0 por não apresentar restrição de sinal, permite que o modelo capture retornos variáveis de escala, o que significa que a eficiência da DMU pode variar conforme a escala de operação muda.

A escolha do modelo BCC orientado a output se justifica, pois, este estudo se pautou na maximização dos produtos resultantes das propriedades leiteiras, ultrapassando a lógica de minimização de inputs consumidos. Para a aplicação bem-sucedida desta técnica, vale ressaltar a necessidade de que o número de variáveis originais selecionadas deve ser de até um terço da quantidade de DMUs abordadas para a análise (Banker *et al.*, 1984; Banker; Morey, 1986; Banker *et al.*, 1989). A fim de gerar resultados que contribuam de fato com a análise de desempenho das propriedades leiteiras no Brasil, este estudo dedicou-se a análises de correlação entre grupos de inputs e outputs, bem como entre as próprias variáveis.

A terceira etapa do modelo correspondeu à aplicação da técnica de Simulação de Monte Carlo. Nesta etapa ocorreu a definição de variáveis originais que foram convertidas em variáveis aleatórias. Isso foi possível a partir da atribuição de distribuições de probabilidade a cada variável selecionada. Trata-se de uma análise de caráter complementar à lógica determinística para a geração de insights sobre DMUs ineficientes. Após a definição dos inputs e outputs que correspondem às variáveis aleatórias do modelo, procedeu-se a compilação da simulação em 5000 iterações. Por fim, foi desenvolvido um benchmark probabilístico de produção, a fim de gerar informações mais consistentes sobre a gestão de desempenho destas propriedades. Acentua-se aqui a utilização dos *softwares* de análise estatística *R-Project 4.2.1*

e *Rstudio* versão 2022.07.2+576 para apoio a cada uma das três etapas do modelo de análise de desempenho proposto.

3 RESULTADOS

Esta seção apresenta os resultados deste estudo.

3.1 Seleção e classificação de variáveis em inputs e outputs para avaliação do desempenho das propriedades leiteiras

Primeiramente, foi aplicada a Análise de Componentes Principais como técnica de pré-processamento de dados e apoio a seleção de variáveis originais do modelo. Logo, para uma base formada por 12 indicadores obteve-se um índice de variabilidade de 91% para os componentes principais I, II e III. Procedeu-se a seleção das variáveis originais observando-se aquelas que apresentaram um índice de correlação e autovalores acima de 0,91. Neste sentido, foram selecionadas 7 variáveis originais. Posteriormente, estas variáveis foram submetidas novamente à análise de correlação a fim de avaliar o comportamento entre insumos, entre produtos e entre insumos e produtos para otimização dos resultados da técnica DEA. Nesta etapa foi obtido um novo índice de variância de 98,99%.

Acentua-se aqui os pressupostos de aplicação da Análise de Componentes Principais, dentre eles, a redução da variabilidade entre componentes considerados. Este comportamento pode ser verificado pelos valores reduzidos dos autovetores e correlações apresentados na Tabela 2, conforme as definições metodológicas deste estudo. Todavia, destaca-se o grande poder explicativo para as dimensões de desempenho consideradas, justificado pelos altos valores observados para a componente principal I. Isto indica que a escolha dos três primeiros componentes principais é suficiente para explicar a variabilidade dos dados.

Tabela 2 - Primeiras variáveis originais mais correlacionadas com PC I, PC II e PC III

(Continua)

Correlação	PC I	PC II	PC III
PPP	0.4694385	0.156281342	0.85349975
QLV	0.9539521	-0.277023367	0.02248451
RL	0.9638174	-0.240082940	0.06855197
QLP	0.9583231	-0.266310083	0.02585994
CEMV	0.9743067	-0.005292066	-0.04742347
AL	0.8739287	0.211522182	-0.03466955
MED	0.9174331	-0.060633892	-0.20202229

Tabela 2 - Primeiras variáveis originais mais correlacionadas com PC I, PC II e PC III

(Conclusão)

Correlação	PC I	PC II	PC III
OR	0.8910025	0.262373771	-0.16704695
EC	0.8356748	0.414154374	-0.18820985
COEL	0.5652220	0.723720633	0.03102920
PD	0.9581789	-0.266857135	0.02595073
VL	0.9100925	-0.197564475	0.01383896

Fonte: Do autor (2024)

Com esta análise foi possível a seleção de 7 variáveis originais das 12 variáveis consideradas inicialmente. Trata-se de um processo que atende aos critérios de pesquisa, pois correspondem as variáveis mais significativas para PC I. Portanto, foram consideradas para análise as variáveis Quantidade de leite vendido (QLV), Receita do leite (RL), Quantidade de leite produzido (QLP), Gastos com concentrado e mineral para vacas (CEMV), Gastos com medicamentos e curativos (MED), Produção diária total (PD), Número de vacas em lactação (VL), que apresentam alta correlação entre si, respeitando o requisito do DEA para a alta correlação entre inputs e outputs. A Tabela 3 representa os valores dos coeficientes de correlação destas variáveis.

Tabela 3 - Matriz de correlação de variáveis originais

	QLV	VL	CEMV	MED	PD	QLP	RL
QLV	1	0.9075559	0.9315131	0.8812883	0.9987611	0.9987793	0.9959169
VL		1	0.8618529	0.7961483	0.9157862	0.9155366	0.9130166
CEMV			1	0.9199215	0.9310590	0.9312315	0.9348247
MED				1	0.8788472	0.8789881	0.8729521
PD					1	0.9999989	0.9974631
QLP						1	0.9975014
RL							1

Fonte: Do autor (2024)

De acordo com as variáveis selecionadas pode-se inferir que se obteve um modelo satisfatório, com uma correlação alta entre inputs e outputs, representada por 99,87% entre QLV e QLP. Além disso, foi possível a consideração de todas as dimensões de desempenho listadas, a saber, Receita, Custos Operacionais e Produção.

3.2 Análise de Componentes Principais aplicada as propriedades leiteiras do Brasil

A Análise de Componentes Principais baseia-se na interpretação de autovetores e coeficientes de correlação (Brandt; Brandt, 1998). Os autovetores são vetores que determinam a direção dos componentes principais no espaço dos dados (Jolliffe, 2002). Estes são obtidos a partir da matriz de correlação das variáveis originais e para cada autovetor há um autovalor correspondente (Brandt; Brandt, 1998). Os autovalores indicam a quantidade de variância explicada por cada componente principal (Brandt; Brandt, 1998). Assim, o valor absoluto dos coeficientes dos autovetores representam a importância relativa de cada variável original no componente principal (Jolliffe, 2002). O sinal do coeficiente do autovetor indica a direção da relação entre o componente principal e a variável original (Jolliffe, 2002).

Neste estudo a PCA revelou que os três componentes principais (PC I, PC II e PC III) explicam 98,99% da variância total dos dados. Apenas PC I é responsável por explicar 91% deste quantitativo. Logo, procedeu-se um estudo sobre a importância relativa de cada componente com base na variância comparada. A Tabela 4 apresenta os valores dos coeficientes de correlação e autovetores para cada uma das variáveis originais relacionadas aos três primeiros componentes principais.

Tabela 4 - Relação de autovetores (\hat{e}) e correlações (r) entre PC I, PC II e PC III e as variáveis

Variáveis	PC I		PC II		PC III	
	r1	$\hat{e}1$	r2	$\hat{e}2$	r3	$\hat{e}3$
QLV	0,9913414	0,3868825	-0,06237475	-0,127924	-0,1054901	-0,297064
RL	0,9910451	0,3867669	-0,07756917	-0,159086	-0,095498	-0,268926
QLP	0,9925365	0,3873489	-0,07479926	-0,153405	-0,0910721	-0,256463
CEMV	0,960272	0,3747573	0,17129139	0,3512996	0,03976647	0,1119839
MED	0,9177265	0,3581534	0,36691469	0,7525012	0,0837575	0,2358643
PD	0,9925185	0,3873419	-0,07536433	-0,154564	-0,0906135	-0,255171
VL	0,9307606	0,3632402	-0,22934246	-0,470356	0,28417016	0,8002338

Fonte: Do autor (2024)

De acordo com a Tabela 4, considerando os valores absolutos, os maiores valores para os coeficientes de correlação e autovetores foram verificados em todas as variáveis originais, logo no PC I. Ainda assim, a quantidade de leite produzido e a produção diária total destacaram-se com os maiores valores nestes quantitativos. Dessa forma, o primeiro componente principal pode ser interpretado como um “**Índice de eficiência e rendimento da produção leiteira**”.

Cabe ressaltar que todo o conjunto de variáveis apresentou uma correlação positiva com PC I. Assim, quanto maior o escore das 7 variáveis originais, em especial QLP e PD, maior será a pontuação de PC I.

Na análise de coeficientes de correlação e autovetores do segundo componente principal não houve valores altos destes quantitativos em nenhuma das variáveis originais consideradas. No entanto, uma correlação moderada (36,69%) foi verificada para a variável gastos com medicamentos e curativos. Neste sentido, o segundo componente principal pode ser interpretado como um **“Índice de saúde e bem-estar do rebanho”**. Para este componente foram identificadas correlações negativas para todas as variáveis, exceto para gastos com concentrado e mineral para vacas e gastos com medicamentos e curativos. Isso revela que aumentos no escore da variável MED impactam positivamente no crescimento da pontuação de PC II.

Para o terceiro componente principal foi verificado uma redução drástica dos valores absolutos dos coeficientes de correlação e autovetores para todo o conjunto de variáveis originais. Apenas a variável número de vacas em lactação apresentou uma correlação moderada (28,41%) comparada aos escores de correlação das demais variáveis. Assim, o terceiro componente principal pode ser interpretado como um **“Índice de capacidade produtiva do rebanho”**. Também foi verificado uma correlação negativa com PC III para todas as variáveis analisadas, exceto para as variáveis gastos com concentrado e mineral para vacas, gastos com medicamentos e curativos, e número de vacas em lactação. Esta análise sugere que aumentos nos escores das variáveis CEMV e MED promovem um baixo crescimento de PC III, já o aumento dos escores de VL impactam moderadamente no crescimento de PC III.

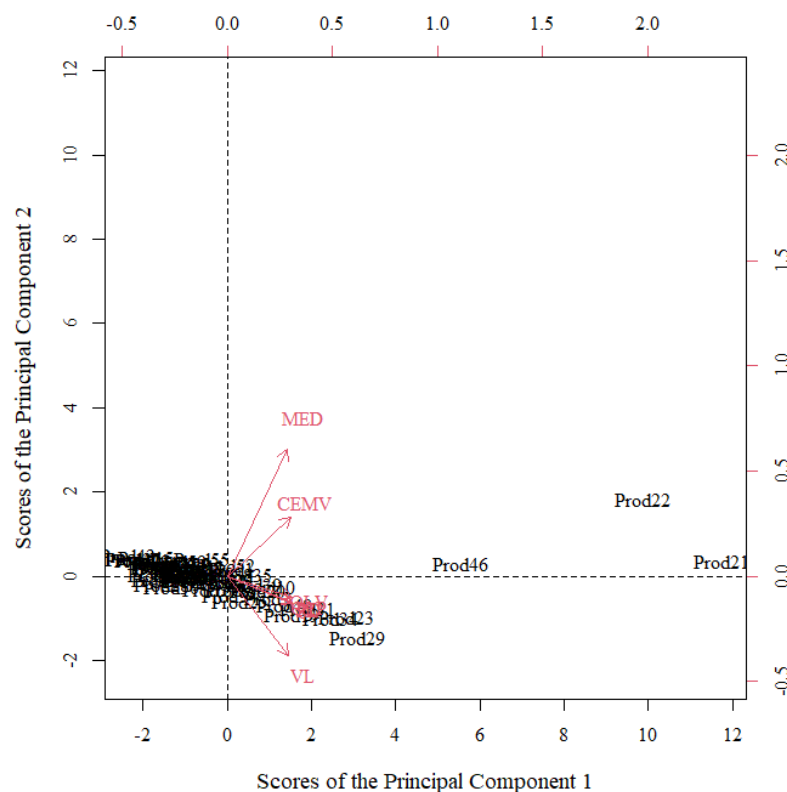
A Figura 2 representa o diagrama de ordenação de variáveis originais para PC I e PC II. Através da figura pode-se observar os escores dos dados projetados nos componentes principais I e II. As setas indicam a direção e a magnitude das variáveis originais no espaço dos componentes principais. Logo, a direção da seta indica o modo de contribuição de cada variável original para o componente, e o seu comprimento indica a importância relativa de cada variável para o componente. Cada ponto no diagrama representa uma unidade amostral, neste caso cada um dos 57 produtores considerados.

Figura 2 - Diagrama de ordenação de variáveis originais para PC I e PC II

(Continua)

Figura 2 - Diagrama de ordenação de variáveis originais para PC I e PC II

(Conclusão)



Fonte: Do autor (2024)


A seta da variável gastos com medicamentos e curativos aponta para o canto superior direito do diagrama o que sugere uma correlação positiva moderada com PC I e PC II. A seta da variável gastos com concentrado e mineral para vacas também apontou para uma direção semelhante à da variável MED, canto superior direito do diagrama, o que indica uma correlação positiva para ambos os componentes. No entanto, CEMV apresentou uma correlação maior que MED para o primeiro componente e menor para o segundo. Este perfil de comportamento das variáveis revela uma possível relação entre elas.

A seta da variável número de vacas em lactação apontou para a região inferior direita do diagrama, o que indica uma correlação positiva moderada com o primeiro componente principal e correlação negativa moderada com o segundo. Já as variáveis quantidade de leite vendido, receita do leite, quantidade de leite produzido e produção diária total apresentaram um comportamento muito semelhante, com setas apontadas na direção inferior direita do diagrama. Nestes casos, ressalta-se a ocorrência de altas correlações positivas com PCI e correlações negativas moderadas com PC II.

Se tratando da dispersão dos dados no espaço dos componentes principais, apenas os produtores 21, 22 e 46 apresentaram um comportamento distinto em relação as variáveis analisadas. Isso porque apresentaram posições mais distantes da massa central de dados. Além disso, sugere-se um comportamento de maior distinção entre PC I e PC II para estes três produtores. Já os 54 produtores restantes que compõe a massa central de dados se posicionaram próximos à origem do diagrama, indicando um comportamento semelhante destes produtores para as 7 variáveis originais analisadas. O destaque do produtor 21 para o PC I esteve associado à sua alta pontuação observada para todas as variáveis originais, em especial, para as variáveis MED e CEMV. Já altos escores obtidos para as variáveis QLP, QLV, RL e PD promoveram o destaque do produtor 21 para PC I, e em menor magnitude o destaque do produtor 46 para o mesmo componente principal.

A Figura 2 representa o diagrama de ordenação de variáveis originais para PC II e PC III. Nele é possível verificar os escores dos dados para o segundo e terceiro componentes principais. Analogamente a análise da Figura 2, na Figura 3 as setas informam sobre a direção e magnitude das variáveis no espaço dos componentes principais.

Figura 3 - Diagrama de ordenação de variáveis originais para PC II e PC III



Fonte: Do autor (2024)

Com base na Figura 3, a seta da variável número de vacas em lactação apontou para o canto superior esquerdo do diagrama, o que sugere uma correlação negativa moderada para o segundo componente principal e uma correlação positiva moderada para PC I. Para as variáveis gastos com concentrado e mineral para vacas e gastos com medicamentos e curativos as setas apontaram em direções semelhantes do diagrama, canto superior direito, o que revela uma correlação moderada positiva para ambos componentes principais. No entanto, ressalta-se a superioridade de magnitude da variável MED em relação a variável CEMV, de acordo com o tamanho das setas observado para estas variáveis.

As variáveis quantidade de leite vendido, receita do leite, quantidade de leite produzido e produção diária total apresentaram setas apontadas para o canto inferior esquerdo do diagrama da Figura 3, indicando correlações negativas com ambos os componentes PC II e PC III. Estas variáveis também apresentaram baixas correlações com estes componentes principais, o que pode ser verificado pelo tamanho das setas ou magnitude das variáveis em questão. No que corresponde a distribuição dos dados no espaço dos componentes PC II e PC III, destacam-se os produtores 22, 29 e 34 com posições mais distantes da massa central de dados. Isso indica a existência de particularidades nestas unidades amostrais em relação ao conjunto amostral restante, de acordo com as variáveis originais consideradas.

No caso do produtor 22, este obteve destaque no segundo componente principal devido a altas pontuações nas variáveis MED e CEMV. De forma análoga, o produtor 29 obteve destaque no componente PC III devido aos altos valores absolutos para as variáveis QLP, QLV, RL e PD, assim como os produtores 2, 7, 10, 21, 24, 31 e 44, em menor magnitude. Já o produtor 34 apresentou destaque para o componente PC III em razão da alta pontuação observada para a variável VL, assim como os produtores 25, 28, 45, 50 e 56 em menor instância.

3.3 Análise da eficiência técnica pura e alvos

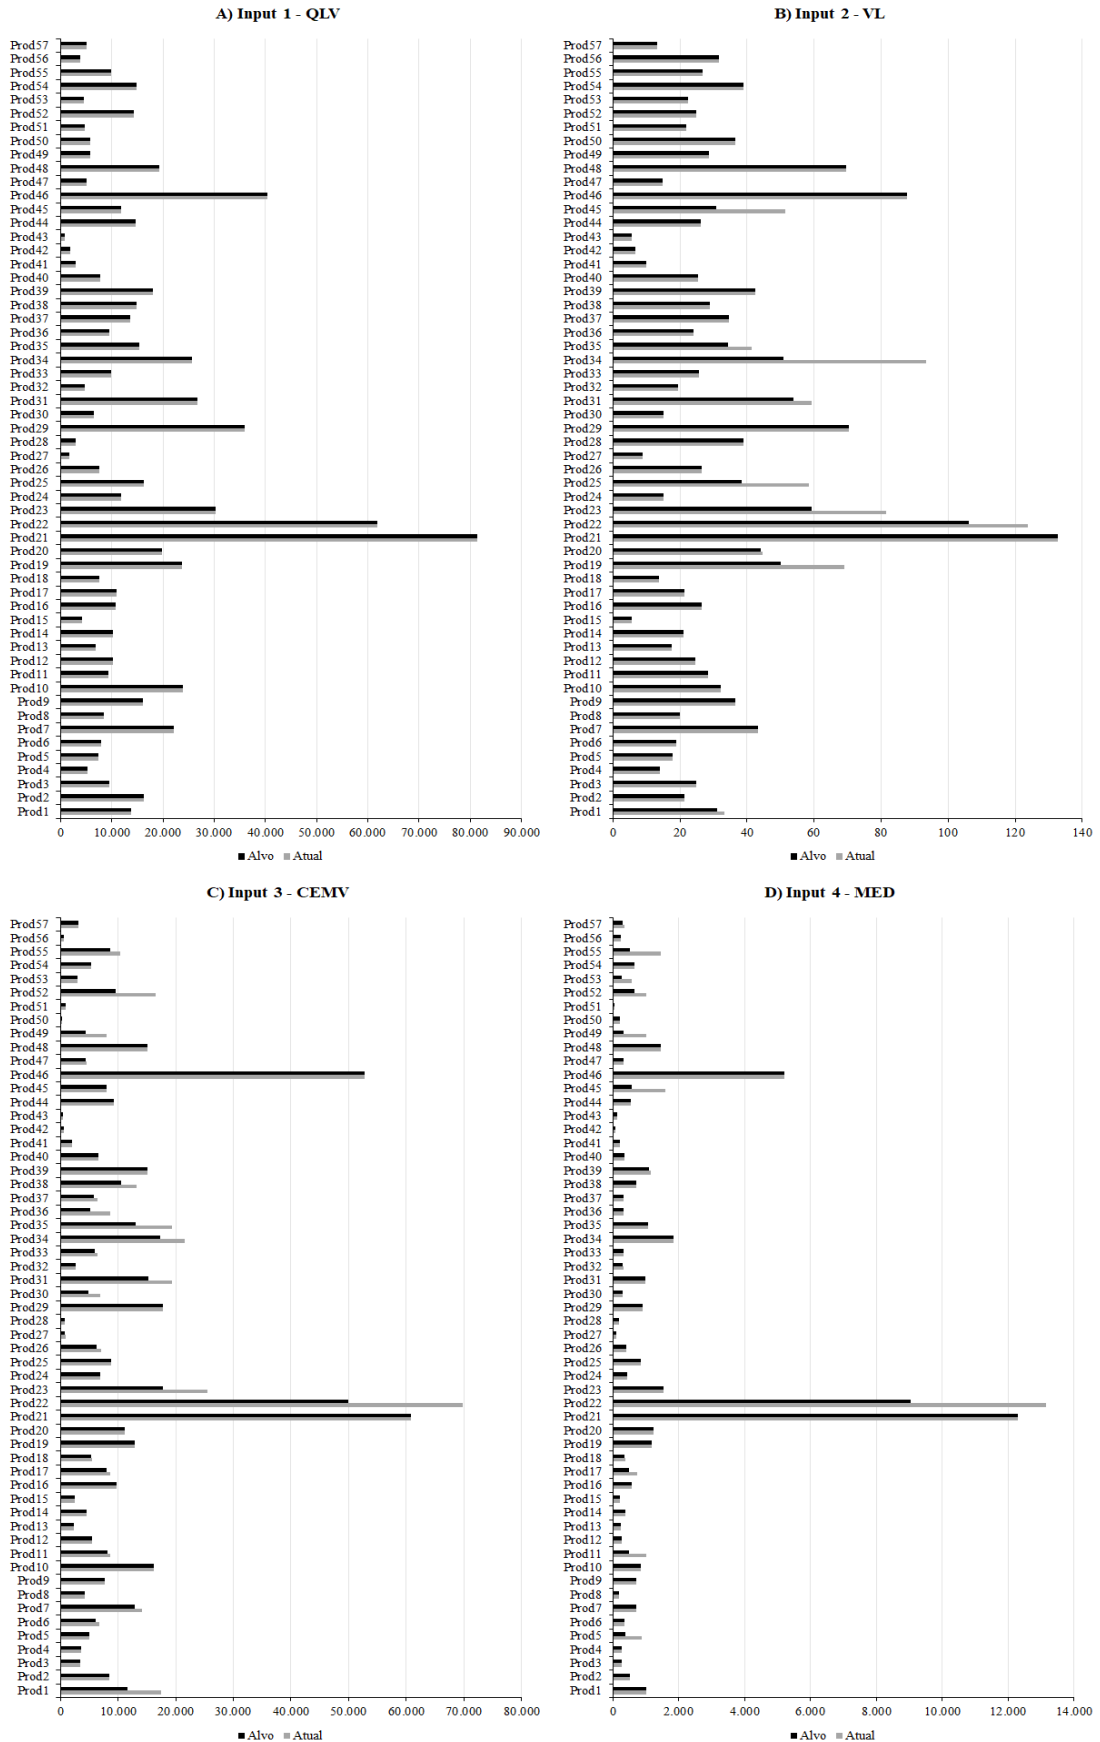
A fim de estimar a eficiência das unidades de tomada de decisão (DMUs) procedeu-se a Análise Envoltória de Dados (DEA). Trata-se de uma análise que promove a identificação de DMUs eficientes e ineficientes bem como beneficia a comparação entre estas unidades. Além disso, a separação das variáveis originais em inputs e outputs neste modelo permite o apontamento de variáveis mais impactantes na eficiência técnica pura das DMUs analisadas. Para tanto, a Figura 4 apresenta os escores de eficiência técnica pura para as DMUs abordadas, no caso, os 57 produtores de leite. Já as Figuras 5 e 6 representam os alvos para inputs e outputs considerados respectivamente.

Figura 4 - Escores de eficiência técnica pura dos 57 produtores




Fonte: Do autor (2024)

Figura 5 - Alvos para os inputs



Fonte: Do autor (2024)

Figura 6 - Alvos para os outputs



Fonte: Do autor (2024)

De acordo com a Figura 4, aproximadamente 35% das DMUs analisadas obtiveram um escore de 100% de eficiência. Estas DMUs corresponderam aos produtores Prod2, Prod3, Prod8, Prod10, Prod13, Prod15, Prod16, Prod21, Prod24, Prod28, Prod29, Prod40, Prod42, Prod43, Prod46, Prod48, Prod50, Prod51, Prod54 e Prod56. Os demais produtores apresentaram escores de eficiência inferiores e que são justificados pelo seu desempenho nos inputs e outputs considerados neste estudo.

Assim este estudo avança com a definição dos escores atuais e alvos das 7 variáveis originais abordadas para os 57 produtores. Conforme os resultados da aplicação da técnica de Análise de Componentes Principais, as 7 variáveis originais selecionadas corresponderam aos inputs Quantidade de leite vendido, Número de vacas em lactação, Gastos com concentrado e mineral para vacas, Gastos com medicamentos e curativos; e aos outputs Produção diária total, Quantidade de leite produzido e Receita do leite.

Inicialmente, a Figura 5 (a) contemplou os escores do input Quantidade de leite vendido (QLV). Dentre os 57 produtores analisados, todos apresentaram um desempenho compatível ao alvo. Destaca-se aqui uma média de 14.260,35 litros de leite vendidos para este conjunto de produtores. No entanto, a maioria apresenta um escore para a variável QLV abaixo da média, especificamente, 36 produtores. Isso revela uma predominância de pequenos e médios produtores para o conjunto amostral considerado.

O próximo input analisado correspondeu ao Número de vacas em lactação (VL), conforme a Figura 5 (b). Para esta variável foi observado um total de 47 DMUs com desempenho atual equivalente ao valor alvo. Apenas 10 produtores necessitam reduzir o número de vacas em lactação para que alcance um desempenho favorável neste input. A média atual de vacas em lactação foi de 35 para os 57 produtores, sendo necessária a atualização deste quantitativo para 33 animais. Neste sentido, destacam-se os produtores 23, 25, 34 e 45 com as maiores folgas observadas, na ordem de 22, 20, 43 e 20 animais respectivamente. A redução do rebanho pode favorecer a seleção genética de animais e impactar no aumento de produtividade.

A Figura 5 (c) indica os Gastos com concentrado e mineral para vacas (CEMV). Para este input foi verificado a necessidade de redução de gastos para 23 produtores, sendo que 34 obtiveram valor compatível ao alvo nesta variável. O gasto médio atual com concentrado e mineral para vacas em lactação foi de R\$ 13.680,76. No entanto, aproximadamente 15% do total de produtores analisados apresenta gastos acima da média para a variável. Acentua-se aqui o maior gasto atual verificado para o produtor 22, com uma folga de R\$ 19.841,57. A produtividade dos animais é potencializada com o consumo de concentrado e mineral, todavia,

existem alternativas de suplementação animal que podem ser utilizadas para reduzir custos como, algodão, polpa cítrica, entre outros, bem como o pastoreio dos animais.

O último input analisado correspondeu aos Gastos com medicamentos e curativos (MED), de acordo com a Figura 5 (d). Dentre os 57 produtores analisados, 43 apresentaram um desempenho equivalente ao alvo nesta variável. O gasto médio com medicamentos e curativos foi de R\$ 1.129,96, entretanto, apenas 11 produtores superaram este valor de gastos para esta variável. Desconsiderando o produtores 21 e 22 que apresentaram gastos com medicamentos e curativos de R\$ 12.304,82 e R\$ 13.165,97, a nova média atual de gastos para a variável passa a ser de R\$ 707,94. O gasto com medicamentos e curativos reflete no bem-estar dos animais, e significa um fator condicionante para a melhoria da produtividade destes.

No que se refere aos outputs analisados, a priori, a Figura 6 (a) refere-se aos escores de Produção diária total (PD). Para este output foram verificados 20 produtores com desempenho atual equivalente ao alvo. Assim, aproximadamente 65% do total de produtores necessita ampliar sua produção diária total. Apenas os produtores 21, 22, 23, 29 e 46 ultrapassaram a marca de 1000 litros de produção diária. Os demais produtores apresentaram uma produção diária média de 391,84 litros. Neste aspecto, o desafio consiste em criar alternativas de baixo custo que contribuam com o aumento da produção diária dos animais.

A Figura 6 (b) indica a Quantidade de leite produzido (QLP) por cada produtor mensalmente. Logo, 20 produtores apresentaram escores atuais equivalentes aos alvos nesta variável, com destaque para o produtor 21 que obteve a maior produção mensal, na ordem de 86.082,08 litros de leite. Além disso, as maiores folgas foram verificadas para os produtores 25, 35, 39 e 55, todas acima de 2.500 litros. Considerando uma média de produção mensal de 15.539,77 litros para os 57 produtores, observa-se que deste total 36 produtores ainda produzem abaixo do valor médio. A ampliação da produção mensal contribui para a elevação da receita de produtores, no entanto, aspectos infraestruturais devem ser considerados para que esta evolução seja sustentável.

O último output analisado contemplou o quantitativo da Receita do leite (RL). Para esta variável 37 produtores necessitam realizar ajustes no sentido de ampliar sua fonte de receita mensal. Deste total de produtores, 56% apresentaram folgas de R\$ 552,49 a R\$ 3.914,25, 38% apresentaram folgas de R\$ 4.450,66 a R\$ 7.937,59, já 6% tiveram folgas acima de R\$ 9.000,00. Também se observa uma receita média mensal de R\$ 38.418,66 para o total de 57 produtores, em que apenas 20 apresentaram desempenho superior à média. O aumento da receita do leite trata-se de uma decisão que envolve a combinação eficiente das outras variáveis consideradas

neste modelo. Neste âmbito, deve-se prezar pela maximização da receita a partir da utilização eficiente dos recursos disponíveis em cada propriedade.

A fim de gerar informações relevantes para os produtores de leite sobre como alcançar uma gestão eficiente de seus recursos, este estudo avança na perspectiva de promover uma análise de benchmarks. A análise de benchmarks está pautada na comparação de desempenho de empresas com líderes do setor dotados das melhores práticas de produção. Neste caso, este estudo a partir da Tabela 5 propõe a comparação de produtores ineficientes com produtores eficientes que apresentem um perfil mais próximo de sua realidade. Isso permite que estes produtores ineficientes consigam se planejar de uma maneira mais objetiva e clara, com metas de produção bem definidas para o alcance de eficiência em um curto período.

Tabela 5 – Benchmarks

(Continua)

DMU	Eficiência	Benchmarks	Frequência	DMU	Eficiência	Benchmarks	Frequência
Prod1	0,882605	Prod16, Prod21, Prod29	0	Prod30	0,924649	Prod2, Prod15, Prod16, Prod42	0
Prod2	1	Prod2	12	Prod31	0,972702	Prod16, Prod21, Prod29	0
Prod3	1	Prod3	5	Prod32	0,844839	Prod16, Prod28, Prod43, Prod54	0
Prod4	0,777479	Prod2, Prod15, Prod16, Prod42, Prod43, Prod54	0	Prod33	0,912237	Prod8, Prod16, Prod29, Prod42, Prod51	0
Prod5	0,827814	Prod15, Prod16, Prod43, Prod54	0	Prod34	0,958238	Prod16, Prod21, Prod29	0
Prod6	0,833489	Prod2, Prod8, Prod16, Prod42	0	Prod35	0,863071	Prod16, Prod21, Prod29, Prod46	0
Prod7	0,936234	Prod2, Prod10, Prod16, Prod29	0	Prod36	0,988629	Prod3, Prod8, Prod16, Prod29	0
Prod8	1	Prod8	5	Prod37	0,957689	Prod3, Prod16, Prod29, Prod51	0
Prod9	0,906774	Prod2, Prod16, Prod21, Prod29, Prod54	0	Prod38	0,877429	Prod2, Prod10, Prod16, Prod21, Prod29	0
Prod10	1	Prod10	3	Prod39	0,920614	Prod16, Prod29, Prod46, Prod48	0
Prod11	0,809574	Prod16, Prod28, Prod43	0	Prod40	1	Prod40	2
Prod12	0,92978	Prod3, Prod8, Prod16, Prod29, Prod42, Prod51	0	Prod41	0,907265	Prod16, Prod42, Prod43, Prod54	0

Tabela 5 - Benchmarks

(Conclusão)

DMU	Eficiência	Benchmarks	Frequência	DMU	Eficiência	Benchmarks	Frequência
Prod13	1	Prod13	1	Prod42	1	Prod42	10
Prod14	0,966779	Prod2, Prod3, Prod16, Prod42, Prod54	0	Prod43	1	Prod43	13
Prod15	1	Prod15	8	Prod44	0,941025	Prod2, Prod16, Prod29, Prod42	0
Prod16	1	Prod16	38	Prod45	0,926999	Prod16, Prod28, Prod54	0
Prod17	0,845519	Prod2, Prod15, Prod16	0	Prod46	1	Prod46	4
Prod18	0,936573	Prod2, Prod15, Prod16	0	Prod47	0,847011	Prod16, Prod28, Prod43	0
Prod19	0,951674	Prod16, Prod21, Prod29, Prod54	0	Prod48	1	Prod48	2
Prod20	0,905914	Prod16, Prod21, Prod29, Prod54	0	Prod49	0,814027	Prod16, Prod28, Prod43	0
Prod21	1	Prod21	13	Prod50	1	Prod50	1
Prod22	0,98413	Prod16, Prod21, Prod46	0	Prod51	1	Prod51	4
Prod23	0,989956	Prod16, Prod21, Prod29	0	Prod52	0,941326	Prod2, Prod16, Prod21, Prod16, Prod28, Prod43, Prod54	0
Prod24	1	Prod24	1	Prod53	0,816085	Prod16, Prod28, Prod43, Prod54	0
Prod25	0,854081	Prod16, Prod21, Prod29, Prod54	0	Prod54	1	Prod54	13
Prod26	0,862482	Prod16, Prod28, Prod40, Prod43	0	Prod55	0,816144	Prod16, Prod28, Prod43	0
Prod27	0,927553	Prod16, Prod28, Prod40, Prod43	0	Prod56	1	Prod56	1
Prod28	1	Prod28	10	Prod57	0,886727	Prod15, Prod16, Prod43, Prod54	0
Prod29	1	Prod29	18				

Fonte: Do autor (2024)

De acordo com a análise de benchmarks, apenas os produtores que alcançaram a fronteira de eficiência na análise envoltória de dados, ou seja, que apresentaram escores de eficiência técnica pura igual a 1, podem servir como benchmarks para produtores ineficientes. Neste sentido, se destacaram 20 produtores, a saber, os produtores Prod2, Prod3, Prod8, Prod10, Prod13, Prod15, Prod16, Prod21, Prod24, Prod28, Prod29, Prod40, Prod42, Prod43, Prod46, Prod48, Prod50, Prod51, Prod54 e Prod56. Trata-se de produtores que possuem um conjunto de atributos e melhores práticas de produção focadas na otimização de inputs e maximização de outputs do modelo.

Esta análise revelou, para cada um dos 57 produtores analisados, um conjunto de produtores que correspondem a seus benchmarks, salvo os casos de produtores eficientes que correspondem a seus próprios benchmarks. A partir da análise de frequência destes, destaca-se o produtor 16 que representou o benchmark de um total de 38 produtores ineficientes, ou 67% do conjunto amostral. Todavia, este produtor apresentou um perfil de produção com escores de inputs e outputs abaixo da média do total de produtores. Isso revela que não se trata apenas da minimização de inputs e maximização de outputs, mas também da combinação ótima entre os escores de inputs e outputs. Outros produtores eficientes se destacaram em menor proporção como os produtores 2, 15, 21, 28, 29, 42, 43 e 54.

3.4 Proposição e avaliação de cenários para propriedades ineficientes

A fim de estabelecer diretrizes no âmbito probabilístico para o alcance de eficiência por produtores ineficientes, este estudo avança com a consideração dos resultados da Tabela 6. Trata-se dos valores alvos de cada variável do modelo de eficiência propostos pela aplicação da técnica de Análise Envoltória de Dados. Neste sentido, os produtores ineficientes podem se tornar eficientes caso sigam os valores apresentados. Além disso, estes valores implicam em folgas nulas para cada variável. Em termos gerais, a eficiência pode ser obtida por produtores ineficientes caso estes mantenham seus inputs no mínimo e maximizem seus outputs.

Tabela 6 - Descrição de dados para produtores eficientes

(Continua)

DMU	QLV	VL	CEMV	MED	PD	QLP	RL
Prod1*	13807,2727	31	11.694,10	999,302693	581,69689	17.655,38	43.545,13
Prod2	16185,6364	21	8.496,16	512,427949	558,977273	16.992,91	46.668,10
Prod3	9608,18182	25	3.446,07	272,868895	362,679426	11.025,45	25.461,58
Prod4*	5195,09091	14	3.643,50	256,921464	220,0734	6.681,97	16.129,58
Prod5*	7319	18	4.992,68	381,335579	307,787309	9.348,72	22.598,75
Prod6*	8018,63636	19	6.078,92	357,061087	333,533037	10.124,48	25.053,58
Prod7*	22154,4546	43	12.888,81	698,726196	816,746184	24.816,93	65.875,81
Prod8	8434,27273	20	4.160,77	170,75656	290,200359	8.822,09	21.051,37
Prod9*	16171,4546	36	7.670,03	708,260309	633,445675	19.252,17	48.412,68
Prod10	23858,4546	32	16.153,54	841,312562	803,552632	24.428,00	56.395,74
Prod11*	9381,58333	28	8.117,08	494,854394	423,18161	12.839,98	31.365,27
Prod12*	10208,8182	25	5.426,83	277,99064	375,884253	11.421,76	28.047,16
Prod13	6839,90909	17	2.306,53	245,372993	257,054426	7.814,45	17.720,19
Prod14*	10263,7273	21	4.578,74	366,996209	382,938249	11.640,90	29.658,01
Prod15	4159,81818	6	2.506,30	213,271818	149,04012	4.539,09	10.366,72
Prod16	10729,9091	26	9.661,02	561,299396	480,378544	14.573,64	35.708,49
Prod17*	10937	21	8.003,84	482,753084	438,750252	13.323,24	33.835,61

Tabela 6 - Descrição de dados para produtores eficientes

(Conclusão)

DMU	QLV	VL	CEMV	MED	PD	QLP	RL
Prod18*	7646	14	5.371,40	353,660296	299,09506	9.088,59	22.491,86
Prod19*	23698,25	50	12.905,11	1.164,25	887,829832	26.982,19	69.784,94
Prod20*	19835,75	44	11.197,99	1.236,89	770,072982	23.400,76	58.717,25
Prod21	81355,4167	133	60.820,90	12.304,82	2.831,65	86.082,08	213.065,81
Prod22*	61930,29	106	50.009,65	9.031,75	2.180,78	66.303,35	165.865,86
Prod23*	30240,8182	59	17.766,18	1.540,19	1.095,10	33.280,53	88.044,80
Prod24	11864,0909	15	6.962,25	427,376724	403,274521	12.259,55	28.097,34
Prod25*	16200,9091	39	8.841,56	830,863886	652,062682	19.811,83	49.199,59
Prod26*	7549,63636	27	6.288,32	401,312988	338,047822	10.258,71	25.212,40
Prod27*	1705	9	718,772774	104,280273	69,543768	2.113,58	4.924,47
Prod28	2940,5	39	679,212941	175,802498	150,688048	4.580,92	10.654,15
Prod29	36042,6364	70	17.707,01	903,308381	1.263,62	38.414,00	104.975,77
Prod30*	6454,90909	15	4.806,22	298,115769	268,017693	8.137,14	20.019,84
Prod31*	26746,5833	54	15.299,31	983,330708	979,137466	29.753,79	79.234,34
Prod32*	4720,83333	19	2.678,29	279,064002	206,131316	6.261,32	15.143,94
Prod33*	9837,33333	26	5.883,68	315,276645	382,293311	11.610,47	28.802,23
Prod34*	25670,4546	51	17.247,97	1.829,63	959,07885	29.138,47	75.020,42
Prod35*	15394,5833	34	13.068,72	1.071,92	630,837498	19.154,28	48.143,34
Prod36*	9594,75	24	5.151,75	315,996846	372,765518	11.324,86	26.846,36
Prod37*	13560,1818	35	5.717,09	311,472959	488,525745	14.848,44	38.105,76
Prod38*	14894,9461	29	10.468,75	718,847948	582,817264	17.699,38	45.567,87
Prod39*	18036,0933	42	15.142,10	1.098,26	711,005414	21.597,08	56.063,81
Prod40	7796,16667	25	6.606,77	339,744316	317,572542	9.641,17	25.316,13
Prod41*	3052,08333	10	2.068,61	196,767091	129,498306	3.932,61	9.478,78
Prod42	1907	7	638,922916	60,769274	71,223086	2.165,18	4.935,33
Prod43	807,818182	6	410,864151	127,821219	34,348086	1.044,18	2.497,35
Prod44*	14649,2727	26	9.265,36	539,226556	553,292625	16.807,64	44.275,34
Prod45*	11748,9167	31	7.970,27	576,163075	508,326563	15.433,78	37.640,61
Prod46	40420,5515	88	52.728,68	5.213,30	1.441,29	43.902,93	120.725,65
Prod47*	5016,58333	15	4.314,58	311,168288	223,784213	6.790,44	16.596,75
Prod48	19323,1818	70	15.080,73	1.462,73	756,400908	22.935,91	59.618,10
Prod49*	5886,45455	29	4.411,00	330,396417	271,39162	8.237,76	19.931,44
Prod50	5758,18182	36	233,601169	215,716455	237,301431	7.190,00	16.709,40
Prod51	4748,5	22	935,994877	46,006009	178,412432	5.419,40	12.076,99
Prod52*	14304,9091	25	9.586,13	657,898269	545,744143	16.576,62	43.258,81
Prod53*	4606,83333	23	2.942,02	274,789309	207,787911	6.309,80	15.233,65
Prod54	14929,5833	39	5.375,28	655,849147	609,772478	18.537,08	44.930,82
Prod55*	9828,72727	27	8.696,57	518,662408	441,346753	13.390,25	32.765,66
Prod56	3771,90909	32	540,665825	241,27502	160,697794	4.880,55	12.088,33
Prod57*	5089,81818	13	3.079,71	286,647842	209,295833	6.360,19	15.284,74

*DMU aprimorada conforme os alvos estipulados.

Fonte: Do autor (2024)

De acordo com a Tabela 6, um total de 37 produtores necessitam de ajustes nas variáveis do modelo para alcance da fronteira de eficiência. A partir da descrição dos dados, este estudo realizou comparações de ajustes de funções de distribuição para cada variável do modelo,

considerando os dados modificados para produtores eficientes. Para tanto, a análise foi pautada no menor valor obtido para a estatística Kolmogorov-Smirnov (KS). Trata-se de uma estatística não paramétrica da igualdade de distribuições de probabilidade unidimensionais contínuas que pode ser usada para comparar uma amostra com uma distribuição de probabilidade de referência (Prakash, Mohanty, 2017). As comparações de ajustes foram expressas na Tabela 7.

Tabela 7 - Comparações de ajustes para variáveis do modelo

Ajuste de distribuição	QLV	VL	CEMV	MED	PD	QLP	RL
LogLogistic	0.0483*	0.0530*	0.0749	0.0761	0.0456	0.0457	0.0655
Pearson5	0.0511	0.0599	0.0731*	0.0759*	0.0402*	0.0402*	0.0588
Lognorm	0.0631	0.0674	0.0834	0.0946	0.0488	0.0489	0.0509*
InvGauss	0.0741	0.0759	0.0931	0.1183	0.0548	0.0548	0.0599
Gamma	0.0992	0.0878	N/A	0.1918	0.0742	0.0742	0.0811
ExtValue	0.1096	0.0937	0.1093	0.2240	0.0950	0.0946	0.1006
Expon	0.1363	0.0947	0.0997	0.2132	0.1596	0.1595	0.1492
Logistic	0.1367	0.1037	0.1669	N/A	0.1199	0.1200	0.1265
Laplace	0.1597	0.1198	0.1901	0.3049	0.1451	0.1449	0.1590
Pert	0.1969	0.1743	0.2307	0.5270	0.1487	0.1489	0.1524
Normal	0.2168	0.1822	0.2186	0.3434	0.1814	0.1815	0.1913
Levy	0.2869	0.2638	0.2811	0.2581	0.3035	0.3034	0.2869
ExtValueMin	0.3136	0.2992	0.3358	0.4217	0.2977	0.2978	0.2931
Pareto	0.3752	0.3346	0.3729	0.3571	0.3799	0.3804	0.3753
Triang	0.4327	0.3426	0.4619	0.7132	0.3877	0.3873	0.3851
Uniform	0.5841	0.5329	0.6507	0.7949	0.5724	0.5725	0.5629

* Menor valor da estatística Kolmogorov-Smirnov (KS)

Fonte: Do autor (2024)

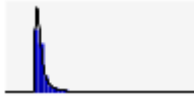
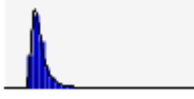


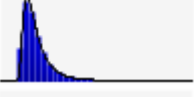
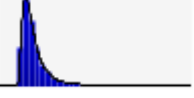
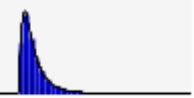
Conforme a Tabela 7, foram consideradas para a análise de ajuste as distribuições LogLogística (LogLogistic), Pearson (Pearson5), Log Normal (Lognorm), Gauss Invertida (InvGauss), Gamma, Valor Extremo (ExtValue), Exponencial (Expon), Logística (Logistic), Laplace, Pert, Normal, Levy, Valor Extremo Mínimo (ExtValueMin), Pareto, Triangular (Triang) e Uniforme (Uniform). A partir dos resultados indicados no ajuste de distribuições, a Simulação de Monte Carlo foi viabilizada. Neste contexto, foram definidos o conjunto de parâmetros de cada variável do modelo de acordo com a distribuição indicada na etapa de ajuste, conforme apresentado na Tabela 8.

Tabela 8 - Inputs do modelo de simulação

(Continua)

Tabela 8 - Inputs do modelo de simulação

(Conclusão)

Variável	Função	Distribuição	Mínimo	Máximo	Média
QLV	RiskLoglogistic(-207,53;10504;2,2033;RiskName("QLV"))		-6,00	263.609,25	14.783,28
VL	RiskLoglogistic(-0,78048;27,624;2,9464;RiskName("VL"))		1,55	396,23	32,85
CEMV	RiskPearson5(2,8735;23766;RiskShift(-3044);RiskName("CEMV"))		1.043,02	140.154,39	9.557,34
MED	RiskPearson5(1,8306;776,41;RiskShift(-61,196);RiskName("MED"))		2,41	27.666,35	844,66
PD	RiskPearson5(4,0429;2159,9;RiskShift(-169,59);RiskName("PD"))		-11,61	4.786,44	538,46
QLP	RiskPearson5(4,0354;65423;RiskShift(-5138,7);RiskName("QLP"))		-594,68	171.149,08	16.388,45
RL	RiskLognorm(44401,9;36692,5;RiskShift(-3083,9);RiskName("RL"))		527,77	409.086,56	41.354,09

Fonte: Do autor (2024)

De acordo com a Tabela 8 foi realizada a definição dos parâmetros de eficiência para os produtores de leite. Foi verificado um melhor desempenho para as variáveis Quantidade de leite vendido (QLV) e Número de vacas em lactação (VL) com a distribuição Log-Logística. Já as variáveis Gastos com concentrado e mineral para vacas (CEMV), Gastos com medicamentos e curativos (MED), Produção diária total (PD) e Quantidade de leite produzido (QLP) obtiveram uma melhor pontuação com a distribuição Pearson.





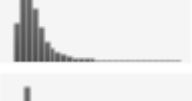


Por fim, o output Receita do leite (RL) teve um melhor desempenho com a distribuição Log-Normal. Trata-se de distribuições que podem ser utilizadas como benchmarks probabilísticos para produtores ineficientes, a fim de compreender e potencializar seus resultados respeitando os intervalos especificados para valor mínimo, máximo, média, 1º percentil, 99º percentil e erro 0, conforme os resultados do modelo de simulação apresentados na Tabela 9.

Tabela 9 - Outputs do modelo de simulação

(Continua)

Tabela 10 - Outputs do modelo de simulação

(Conclusão)

Variável	Distribuição	Mínimo	Máximo	Média	1%	99%	Erro
QLV		-6,00	263.609,25	14.783,28	1.039,04	81.664,58	0
VL		1,55	396,23	32,85	4,88	129,71	0
CEMV		-1.043,02	140.154,39	9.557,34	-174,59	55.225,44	0
MED		2,41	27.666,35	844,66	59,63	6.558,81	0
PD		-11,61	4.786,44	538,46	42,31	2.363,36	0
QLP		-594,68	171.149,08	16.388,45	1.337,19	72.404,88	0
RL		527,77	409.086,56	41.354,09	3.259,19	178.521,43	0

Fonte: Do autor (2024)

Os resultados da etapa de simulação foram promissores ao indicar uma configuração probabilística ótima para o alcance de eficiência de produtores de leite. A partir deste conjunto de variáveis podem ser obtidos ganhos para stakeholders da cadeia de produção do leite. Por exemplo, este estudo pode subsidiar insights importantes para produtores sobre suas operações, permitindo que ajustes de eficiência sejam realizados. Para consultores e especialistas do setor agropecuário pode amparar o desenvolvimento de novas tecnologias, e potencializar suas sugestões de soluções de problemas.

Este estudo também beneficia instituições financeiras que podem através desta configuração para produtores eficientes, determinar os riscos de crédito e financiamento de produtores. Cabe ressaltar os impactos deste estudo na indústria de insumos e medicamentos que podem se pautar nos dados de variabilidade apresentados para melhor atender às necessidades dos produtores.

4 DISCUSSÃO

A pecuária leiteira é um setor de influência na economia mundial, impactando na renda de muitas famílias, especialmente de pequenos e médios produtores. Por se tratar de um setor amplo, aborda uma vasta cadeia de produção com diferentes operações e recursos. Logo, a otimização do consumo de recursos é uma questão importante para o alcance de eficiência no setor. A eficiência operacional pode ser alcançada mediante ajustes na rotina das propriedades pautados em boas práticas de produção. A realização de ajustes nas operações confere estabilidade financeira aos produtores, e reduz sua exposição aos riscos inerentes à volatilidade de mercado e questões climáticas.

A eficiência na produção do leite pode ser alcançada com o monitoramento das fontes de ineficiência. As fontes de ineficiência podem se relacionar a problemas de manejo, falta de tecnologia e automação, gestão inadequada de dados e falta de capacitação técnica de colaboradores, entre outros. Especialmente, no caso de pequenos e médios produtores observa-se a ocorrência de fontes de ineficiência com maior frequência. Isso pode estar associado a questões de infraestrutura, dificuldades de acesso a crédito e financiamento, bem como à própria inexperiência de alguns produtores, uma vez que se trata de um setor com uma pequena barreira de entrada.

No âmbito acadêmico, estudos têm sido realizados na perspectiva de análise de eficiência de produção do leite em diferentes regiões do mundo. Por exemplo, Kouriati *et al.* (2023) avaliaram a eficiência de propriedades leiteiras da unidade regional de Pieria. Neste estudo os autores utilizaram a técnica de Análise Envoltória de Dados com retornos constantes de escala. Os resultados indicaram que as propriedades precisam reduzir o consumo de seus recursos em 34,6% para o alcance da fronteira de eficiência. Todavia, os autores não avançaram suas análises com a consideração de retornos variáveis de escala, e sobretudo, no plano probabilístico com a definição de variáveis aleatórias.

Sefeedpari, Shokoohi e Pishgar-Komleh (2020) realizaram uma análise de eficiência de 25 províncias Iranianas durante os últimos 22 anos. Para tanto, os autores empregaram a técnica DEA utilizando como insumos o uso de energia e como saídas a produção de leite. Neste sentido foi viabilizada uma ampla discussão sobre a utilização da eficiência técnica como um indicador-chave do uso de energia nos sistemas de produção leiteira. Neste estudo, foi realizado uma simulação de caráter comparativo entre os modelos CCR e BCC orientados a input. Todavia, este estudo se dedicou a apresentação de avanços metodológicos a partir da comparação de modelos.

Yu *et al.* (2023) avaliaram a eficiência de propriedades leiteiras da China em pequena, média e grande escala no período de 2004 a 2020. Os autores verificaram a influência da proporção entre o consumo de concentrado versus forragem dos animais, o investimento em medicamentos e boas práticas de prevenção de doenças, preço do leite, nível salarial e ativos fixos na eficiência das propriedades. Entretanto, este estudo não prosseguiu sua análise na proposição de benchmarks determinísticos nem probabilísticos para as DMUs consideradas.

Bassoto *et al.* (2021) em seu estudo sobre a eficiência técnica de propriedades leiteiras brasileiras localizadas no estado de Minas Gerais, avaliaram 12 DMUs a partir do modelo BCC com orientação a input. A principal contribuição deste estudo considerou a formação de um índice de comprometimento de insumos, que evidencia o percentual da produção que está comprometida para comprar um determinado insumo. Este escore significou um insight valioso para produtores, assim como a proposta do presente estudo com a geração de benchmarks. Todavia, o estudo de Bassoto *et al.* (2021) se difere deste, pois se concentra na avaliação de eficiência e proposição de benchmarks no plano determinístico.

Assim como nestes trabalhos, o presente estudo foi baseado na avaliação da eficiência de propriedades leiteiras de acordo com um conjunto de variáveis originais. Estas variáveis foram decompostas nos inputs Quantidade de leite vendido (QLV), Número de vacas em lactação (VL), Gastos com concentrado e mineral para vacas (CEMV), Gastos com medicamentos e curativos (MED), e nos outputs Produção diária total (PD), Quantidade de leite produzido (QLP) e Receita do leite (RL). Os resultados da análise de eficiência técnica pura apontaram a existência de fontes de ineficiência para a maioria das propriedades leiteiras analisadas, especificamente, cerca de 65% destas.


A compreensão das causas de existência destas fontes de ineficiências pode ser beneficiada pela análise do perfil destes produtores. Neste sentido, a Figura 7 representa os escores das áreas de produção de cada um dos 57 produtores listados. A análise da área das propriedades permite a separação destes produtores em diferentes escalas de produção.

Figura 7 - Área das propriedades (ha)

(Continua)

Figura 7 - Área das propriedades (ha)

(Conclusão)



Fonte: Do autor (2024)

De acordo com a Figura 7, cerca de 91% dos produtores analisados possuem propriedades com área inferior a 100 hectares. Este valor demonstra a proximidade dos perfis de produtores analisados, sendo classificados em sua maioria como pequenos e médios produtores. No entanto, acentua-se aqui o alto desempenho de propriedades pequenas como Prod2, Prod10 e Prod40, com área inferior a 50 hectares. Já no caso dos produtores 22 e 23 com área superior a 100 hectares, estes apresentaram fontes de ineficiência. Isso revela a inexistência de relações diretas entre eficiência e o tamanho da propriedade.

A análise de benchmarks promoveu destaque para o produtor 16. Com base na Figura 7, verifica-se que este produtor apresenta uma área de produção de pouco mais de 20 hectares. No entanto, é uma propriedade que baseia suas operações em boas práticas de produção com a maximização de outputs e minimização do consumo de insumos, o que a torna referência para a maioria do conjunto amostral analisado. A proposição de benchmarks no plano determinístico pode auxiliar estes produtores a estabelecerem vínculos de produção, com a troca de experiências de modo a potencializar o processo de transição de DMUs ineficientes para DMUs eficientes.

No plano probabilístico, este estudo propôs a definição de ajustes funções de distribuição para cada variável considerada com base em uma matriz de alvos de eficiência. Esta etapa representa um caminho promissor para o alcance da fronteira de eficiência pelas propriedades leiteiras, representando benchmarks probabilísticos para cada produtor. Os

melhores ajustes corresponderam às funções Log-Logística para as variáveis QLV e VL, Pearson para as variáveis CEMV, MED, PD e QLP, e Log Normal para a variável RL.

No caso da variável Quantidade de Leite Vendido (QLV), a distribuição Log-Logística permite a captura da variabilidade de nas vendas que ocorrem mediante a interferência de flutuações de demanda e capacidade de produção por exemplo. Neste sentido, esta distribuição se adequa facilmente a representação tanto de períodos com alta demanda representados por picos na função, quanto baixa demanda representada pelas caudas pesadas na distribuição. Já para a variável Número de Vacas em Lactação (VL), a distribuição Log-Logística pode captar a variabilidade da gestão do rebanho, indicando períodos de flutuações no número de vacas em lactação ocasionados por ciclos reprodutivos e disseminação de doenças por exemplo.

No que se refere às variáveis Gastos com Concentrado e Mineral para Vacas (CEMV) e Gastos com Medicamentos e Curativos (MED), a distribuição de Pearson pode auxiliar na captura da variabilidade e assimetria dos custos em razão da ocorrência de surtos de doenças e flutuações de preços de insumos. Já para as variáveis Produção Diária Total (PD) e Quantidade de Leite Produzido (QLP), a distribuição Pearson pode contribuir para a representação da produção simétrica ou assimétrica de acordo com os perfis de gestão e qualidade do rebanho.

Por fim, a distribuição Log-Normal pode contribuir para a representação da variável Receita do Leite (RL), uma vez que podem ocorrer variações no preço do leite ou na quantidade de leite vendido e/ou produzido, ou ainda mudanças nos hábitos de consumo da população, o que pode ser facilmente detectado por esta distribuição. Neste sentido, as incertezas inerentes a receita podem ser identificadas com precisão, impactando na tomada de decisão assertiva de produtores em suas operações.

5 CONSIDERAÇÕES FINAIS

A pecuária leiteira corresponde a um setor amplo que contribui para a geração de renda e empregos a diferentes classes populacionais. Por se tratar de um alimento de alto consumo, a produção de leite impacta na garantia de segurança alimentar, especialmente em famílias de baixa renda. c Tais aspectos acabam aumentando as distorções existentes no setor e potencializa a divergência de realidade entre pequenos, médios e grandes produtores. Por isso, este estudo propôs um modelo de análise de desempenho na pecuária leiteira, para a geração de insights no âmbito da gestão de desempenho para todas as classes de produtores, de modo a reduzir a desigualdade existente entre pequenos, médios e grandes produtores.

As contribuições práticas estiveram associadas a melhoria da eficiência operacional de propriedades leiteiras. Nesta oportunidade foram propostos benchmarks determinísticos a fim de auxiliar os produtores ineficientes no estabelecimento de metas e melhores práticas de produção no setor, e benchmarks probabilísticos a partir dos ajustes das funções de distribuição de cada variável do modelo a fim de oferecer uma visão mais consistente sobre as fontes de variabilidade e incerteza no contexto de desempenho da cadeia de produção do leite. Estas contribuições se estendem permitindo que estes produtores tomem decisões mais informadas, de modo a otimizarem o consumo de seus recursos em suas propriedades. A análise de benchmarks também contribui para o aumento da competitividade do setor, potencializando a busca por melhorias de qualidade do leite, manejo do rebanho e infraestrutura.

As contribuições teóricas se relacionaram a combinação de diferentes técnicas para a composição do modelo de gestão de desempenho das propriedades leiteiras. Logo, é um estudo que promove insights para o desenvolvimento de novas metodologias inclusive para outros campos de estudo. A combinação de análises determinísticas e probabilísticas promove uma visão holística do cenário analisado, e amplia as possibilidades de tomada de decisão no âmbito da gestão de operações. Também é um estudo que colabora para o arcabouço literário de gestão da agropecuária e serve de apoio para o desenvolvimento de pesquisas futuras.

As implicações políticas do estudo correspondem ao desenvolvimento de políticas públicas de apoio a produção leiteira. Assim, governos podem se beneficiar deste estudo para a geração de programas de incentivo à produção leiteira pautados em benchmarks definidos. O planejamento estratégico eficiente e alocação correta de recursos também satisfaz uma das implicações deste estudo. Além disso, trata-se de um estudo que fornece subsídios para o desenvolvimento de estratégias de mitigação de riscos no setor agropecuário, e promove a redução de desigualdade no setor e desenvolvimento rural. Por fim, a promoção da segurança

alimentar e economia rural, bem como o próprio monitoramento e avaliação de políticas agrícolas pode ser viabilizada com os resultados deste estudo.

As limitações deste estudo estão associadas a integralidade da base de dados, uma vez que apenas 57 produtores apresentavam dados completos para os doze meses do ano de 2022. Também se ressalta as diferenças regionais que podem impactar na divergência de desempenho entre produtores, por se tratar de uma base que ampara 18 estados brasileiros. A implementação de benchmarks é uma proposta interessante para a agilidade dos processos de melhoria de desempenho, no entanto, requer um nível de capacitação de produtores que muitas vezes se mostra ausente.

A fim de propor uma agenda de estudos futuros, este estudo sugere a replicação desta pesquisa com um maior volume de dados, que permita inclusive a observação de evolução de desempenho ao longo dos anos para produtores. Também é sugerido o desenvolvimento de estudos específicos por região considerada, de modo a gerar insights comparativos de desempenho. Por fim, este estudo propõe a realização de pesquisas que integrem a utilização de tecnologias digitais emergentes como inteligência artificial, Big Data e georreferenciamento no processo de coleta de dados, avaliação de desempenho e implementação de benchmarks.

REFERÊNCIAS

- ARVIDSSON SEGERKVIST, Katarina *et al.* Research on environmental, economic, and social sustainability in dairy farming: A systematic mapping of current literature. **Sustainability**, v. 12, n. 14, p. 5502, 2020.
- BANKER, Rajiv D.; MOREY, Richard C. Efficiency analysis for exogenously fixed inputs and outputs. **Operations research**, v. 34, n. 4, p. 513-521, 1986. doi.org/10.1287/opre.34.4.513
- BANKER, Rajiv D.; CHARNES, Abraham; COOPER, William Wager. Some models for estimating technical and scale inefficiencies in data envelopment analysis. **Management science**, v. 30, n. 9, p. 1078-1092, 1984. doi.org/10.1287/mnsc.30.9.1078
- BANKER, Rajiv D. et al. An introduction to data envelopment analysis with some of its models and their uses. **Research in governmental and nonprofit accounting**, v. 5, n. 1, p. 125-163, 1989.
- BASSOTTO, Leandro Carvalho et al. Eficiência técnica em propriedades leiteiras familiares no Estado de Minas Gerais em 2021. **Revista de Economia e Sociologia Rural**, v. 62, n. 1, p. e261483, 2023.
- BRANDT, Siegmund; BRANDT, S. **Data analysis**. Springer-Verlag, 1998.
- CABRERA, Victor E.; FADUL-PACHECO, Liliana. Future of dairy farming from the Dairy Brain perspective: Data integration, analytics, and applications. **International Dairy Journal**, v. 121, p. 105069, 2021.
- CHEN, Zikang; HAN, Song. Comparison of dimension reduction methods for DEA under big data via Monte Carlo simulation. **Journal of Management Science and Engineering**, v. 6, n. 4, p. 363-376, 2021.
- DITTRICH, I. *et al.* Combining multivariate cumulative sum control charts with principal component analysis and partial least squares model to detect sickness behaviour in dairy cattle. **Computers and Electronics in Agriculture**, v. 186, p. 106209, 2021.
- FEIL, Alexandre André *et al.* Sustainability performance of small and medium dairy enterprises in Brazil. **Sustainable Production and Consumption**, v. 39, p. 301-310, 2023.
- FERREIRA, Daniel Furtado. **Estatística multivariada**. Lavras: Editora Ufla, 2011.
- GIVENS, D. I. MILK Symposium review: The importance of milk and dairy foods in the diets of infants, adolescents, pregnant women, adults, and the elderly. **Journal of dairy science**, v. 103, n. 11, p. 9681-9699, 2020.
- GODFREY, Sosheel Solomon; IP, Ryan HL; NORDBLOM, Thomas Lee. Risk analysis of Australia's Victorian dairy farms using multivariate copulae. **Journal of Agricultural and Applied Economics**, v. 54, n. 1, p. 72-92, 2022.
- HOSAMANI, S. B.; HIREMATH, G. K.; SASTRY, KN Ranganath. Financial dimensions influencing the performance of a RRB: principal component approach. 1996.

JOHNSON, R. A. & WICHERN, D. V. Applied multivariate statistical analysis. (6th ed). Upper Saddle River, New Jersey: Prentice Hall. 2007.

JOLLIFFE, Ian T. **Principal component analysis for special types of data**. Springer New York, 2002.

KOURIATI, Asimina *et al.* The Impact of Data Envelopment Analysis on Effective Management of Inputs: The Case of Farms Located in the Regional Unit of Pieria. **Agronomy**, v. 13, n. 8, p. 2109, 2023.

KOVÁCS, Krisztián; SZÚCS, István. Exploring efficiency reserves in Hungarian milk production. **Studies in Agricultural Economics**, v. 122, n. 1, p. 37-43, 2020.

MAINA, Florence *et al.* Factors influencing economic efficiency of milk production among small-scale dairy farms in Mukurweini, Nyeri County, Kenya. **Tropical animal health and production**, v. 52, p. 533-539, 2020.

MASELLO, M. *et al.* Effect of reproductive management programs for first service on replacement dairy heifer economics. **Journal of Dairy Science**, v. 104, n. 1, p. 471-485, 2021.

OJO, Oluwaseun Mercy *et al.* Unraveling the impact of variable external input use on the cost efficiency of dairy farms in Europe. **Environmental and Sustainability Indicators**, v. 8, p. 100076, 2020.

PRAKASH, Anand; MOHANTY, Rajendra P. DEA and Monte Carlo simulation approach towards green car selection. **Benchmarking: An International Journal**, v. 24, n. 5, p. 1234-1252, 2017.

RUVIARO, Clandio Favarini *et al.* Life cycle cost analysis of dairy production systems in Southern Brazil. **Science of the Total Environment**, v. 741, p. 140273, 2020.

SEFEEDPARI, Paria; SHOKOOHI, Zeinab; PISHGAR-KOMLEH, Seyyed Hassan. Dynamic energy efficiency assessment of dairy farming system in Iran: Application of window data envelopment analysis. **Journal of Cleaner Production**, v. 275, p. 124178, 2020.

SHARMA, Navin *et al.* Predicting solar generation from weather forecasts using machine learning. In: **2011 IEEE international conference on smart grid communications (SmartGridComm)**. IEEE, 2011. p. 528-533.10.1109/SmartGridComm.2011.6102379

SIAFAKAS, Stavros *et al.* Identification of efficient dairy farms in Greece based on home grown feedstuffs, using the Data Envelopment Analysis method. **Livestock Science**, v. 222, p. 14-20, 2019.

SINHA, Sanjana *et al.* Digital video watermarking using discrete wavelet transform and principal component analysis. **International Journal of Wisdom Based Computing**, v. 1, n. 2, p. 7-12, 2011.

SIQUEIRA, Tiago Teixeira da Silva *et al.* Organizational forms and agri-environmental practices: The case of Brazilian dairy farms. **Sustainability**, v. 13, n. 7, p. 3762, 2021.

TADAYON, Farhad; LIU, Ming C. Principal component analysis: a tool for assembly management. **Computers & industrial engineering**, v. 25, n. 1-4, p. 77-80, 1993.[doi.org/10.1016/0360-8352\(93\)90225-M](https://doi.org/10.1016/0360-8352(93)90225-M)

WANKAR, Alok K.; RINDHE, Sandeep N.; DOJJAD, Nandkumar S. Heat stress in dairy animals and current milk production trends, economics, and future perspectives: the global scenario. **Tropical Animal Health and Production**, v. 53, n. 1, p. 70, 2021.

YAGHOUBI, Ali; FAZLI, Safar. Proposing a Model to Forecast the Efficiency of Bank Branches under Uncertainty Conditions based on SDEA-PCA Approach and Monte Carlo Simulation. **Modern Research in Decision Making**, v. 6, n. 4, p. 1-33, 2021.

YU, Zetian *et al.* Production efficiency of raw milk and its determinants: Application of combining data envelopment analysis and stochastic frontier analysis. **Agriculture**, v. 13, n. 2, p. 370, 2023.

ARTIGO 2 – PREVISÃO DE OSCILAÇÕES NO PREÇO DO LEITE PROMOVE A PERMANÊNCIA DE PEQUENOS E MÉDIOS PRODUTORES NO SETOR

Resumo

A pecuária leiteira impacta na economia global, desenvolvimento rural e segurança alimentar populacional. Através dela é viabilizada a integração de setores diversos e sobretudo o inter-relacionamento de agentes no processo. A garantia de renda, circulação de capital e movimentação da economia de outros setores estão entre as contribuições deste da pecuária leiteira. Todavia, a volatilidade de preços do leite corresponde a uma das principais causas de evasão de pequenos e médios produtores do setor. Logo, o objetivo deste estudo foi fornecer informações relevantes sobre a dinâmica de preços do leite para produtores a partir da aplicação da técnica de Redes Neurais Artificiais. Para tanto, o estudo ocorreu em 4 etapas, a saber, Definição do problema, Coleta, pré-processamento e divisão dos dados, Seleção e construção do modelo, Desenvolvimento e implantação do modelo. Os resultados indicaram um bom desempenho da rede neural para a classificação mensal da dinâmica de preços do leite com uma acurácia de 87,7%, precisão de 86,57% e erro quadrático médio (MSE) de 0,1229. As limitações corresponderam ao tempo de treinamento da rede e a necessidade de recursos computacionais robustos. Sugere-se a replicação deste estudo para um conjunto amostral maior, que considere variáveis climáticas no modelo. Também se sugere a adoção de outros algoritmos de machine learning para a previsão da volatilidade do preço do leite, a fim de gerar insights comparativos entre diferentes técnicas. Em suma, a previsão de oscilações no preço do leite promove a permanência de pequenos e médios produtores no setor.

Palavras-chave: Previsão; preço; leite, pecuária; redes neurais artificiais.

1 INTRODUÇÃO

A pecuária leiteira contempla um setor amplo que contribui para o desenvolvimento de muitos países, principalmente, países com economias fortemente apoiadas no agronegócio (Feil *et al.*, 2023; Yu *et al.*, 2023). A produção do leite cria incentivos para a geração de renda e emprego para todas as classes de pessoas (Cabrera; Fadul-Pacheco, 2021). Isso permite a inclusão do público economicamente vulnerável formado por pequenos e médios produtores na atividade (Martinelli *et al.*, 2022). Considerando que a pecuária leiteira apresenta uma pequena barreira de entrada, estes produtores não encontram grandes dificuldades para iniciar sua produção (Leitgeb *et al.*, 2023). No entanto, a permanência na atividade a longo prazo é complexa e impõe desafios a todos os produtores, o que exige planejamento e gestão eficiente de recursos (Ruviaro *et al.*, 2020; Arvidsson Segerkvist *et al.*, 2020; Jebari *et al.*, 2022).

Países como Índia, Estados Unidos e Brasil apresentam uma cadeia de produção do leite robusta e que contribui para o crescimento do Produto Interno Bruto (PIB) (Arvidsson Segerkvist *et al.*, 2020; IBGE, 2023). Logo, trabalhar mecanismos para a melhoria de eficiência de produção do leite representa um pilar para o desenvolvimento do setor nestes países (Gori Maia *et al.*, 2022). Para tanto, a realização de programas que visem a melhoria da qualidade, tecnologia, manejo adequado e bem-estar dos animais é fundamental para alcance de melhores índices de produtividade (Liu *et al.*, 2020). Todavia, são ações que incorrem em custos para os produtores e/ou gestores e que são inacessíveis para alguns pequenos e médios produtores (Lau *et al.*, 2022).

A volatilidade dos preços associada às mudanças climáticas representam alguns dos motivos de abandono de pequenos e médios produtores na atividade (Arvidsson Segerkvist *et al.*, 2020; Cabrera; Fadul-Pacheco, 2021). Além disso, a dificuldade de acesso ao crédito é uma barreira econômica para estes produtores. Trata-se de um fator que dificulta a realização de investimentos em infraestrutura e capacitação de colaboradores e impõe limitações para a melhoria da qualidade e implementação de boas práticas de manejo dos animais (Romaniuk *et al.*, 2021). Segundo Yu *et al.* (2023) em seu estudo sobre eficiência da cadeia produtiva do leite cru na China, os autores consideram os custos com alimentação, mão de obra, medicamentos, e o preço do leite como variáveis de alto impacto na eficiência de produção. No entanto, este estudo se concentra no cálculo dos escores de eficiência, e não avança com a geração de insights de produção para os produtores e/ou gestores.

A quantidade de leite produzido por animal é uma variável de interesse dos produtores e que pode ser otimizada mediante ajustes na rotina dos animais (Liseune *et al.*, 2021). A

produtividade dos animais pode indicar a necessidade de reposição do rebanho, detectar doenças precocemente, bem como subsidiar ajustes na dieta. Neste âmbito, a fim de propor informações aos produtores sobre o nível de produtividade dos animais, Liseune *et al.* (2021) utilizaram algoritmos de deep learning para estimar a curva de lactação de animais de acordo com dados históricos de ciclos anteriores. Todavia, os autores não avançaram na perspectiva econômica com a consideração de variáveis como o preço do leite, logo, trata-se de um modelo de previsão de produção.

A utilização de técnicas de machine learning na pecuária leiteira tem se tornado recorrente e promissora (Achour *et al.*, 2020; Tassinari *et al.*, 2021; Atalan, 2023; Zheng *et al.*, 2023). Logo, tomada de decisões referentes ao consumo eficiente de recursos e atualização das operações de produção do leite são viabilizadas com a implementação destas técnicas (Zhang, 2020; Vasafi *et al.*, 2021). Além da capacidade de previsão de algoritmos de machine learning, destacam-se as contribuições para o setor da pecuária leiteira pautados no reconhecimento de imagens (Achour *et al.*, 2020; Tassinari *et al.*, 2021). Isso permite o monitoramento em tempo real do rebanho, facilitando as operações de produção e estimulando o cumprimento da rotina destes animais a partir de boas práticas de manejo (Zheng *et al.*, 2023).

No âmbito da pecuária leiteira, os desafios de comercialização do leite se estendem a questão das flutuações de mercado, a concorrência internacional, a custos de produção elevados, regulamentações governamentais, e processos logísticos por exemplo (Maina *et al.*, 2020). Logo, dispor de informações prévias sobre o comportamento do preço do leite é justificável e aplicável ao contexto de melhoria de eficiência das propriedades leiteiras. Atalan (2023) em seu estudo sobre a cadeia produtiva de leite da Turquia compara diferentes técnicas de machine learning para a previsão do preço do leite pago ao produtor. Todavia, este estudo não avança com a proposição de insights aos produtores e se concentra na comparação de eficiência entre técnicas, o que sugere um trabalho de teor metodológico.

A consideração de variáveis sociais, ambientais e econômicas para composição de uma rede neural artificial (RNA) que faça previsões do comportamento do preço do leite pode representar uma informação valiosa para a orientação de produtores na atividade. Isso porque há a possibilidade de identificação de melhores épocas para a comercialização do leite, compra de insumos e investimentos em infraestrutura. Neste sentido, este estudo avança com a seguinte questão de pesquisa: Como a implementação de uma rede neural artificial pode contribuir para a geração de insights para produtores sobre o preço do leite?


Este estudo contribui de forma objetiva para a tomada de decisão de produtores no plano econômico de produção do leite. Além disso, promove o conhecimento desta classe sobre

variáveis de alto impacto na comercialização do produto, tornando as decisões mais informadas e diretas. Esta metodologia ainda permite que haja a antecipação de produtores a possíveis falhas e influência de fatores externos na atividade. Acentua-se aqui o potencial de contribuição deste estudo na composição de um modelo de gestão de desempenho da pecuária leiteira, onde aspectos de desenvolvimento regional, a partir da geração de empregos e renda para a população são contemplados. Para tanto, o objetivo geral do estudo foi fornecer informações relevantes sobre a dinâmica de preços do leite para produtores a partir da aplicação da técnica de Redes Neurais Artificiais.

2 METODOLOGIA

Este estudo foi construído nos moldes de uma pesquisa descritiva com abordagem quantitativa e lógica indutiva. O estudo ainda se apoiou no campo do machine learning a partir da utilização da técnica de Redes Neurais Artificiais (RNAs) para análise de dados. Segundo Silva (2016), as RNAs representam modelos computacionais que aprendem com os dados fornecidos e realizam tarefas específicas. Uma rede neural é composta por nós interconectados que são distribuídos ao longo de camadas de entrada, camadas intermediárias e de saída. As RNAs podem ser diferenciadas quanto a estrutura adotada, neste caso, redes *perceptron* simples e *perceptron* multicamadas de acordo com a quantidade de camadas apresentadas (Braga; Ludermir; Carvalho, 2000; Silva, 2016). A Figura 1 representa os componentes de uma rede neural artificial *perceptron* multicamadas.

Figura 1 - Componentes de uma rede neural artificial multicamadas

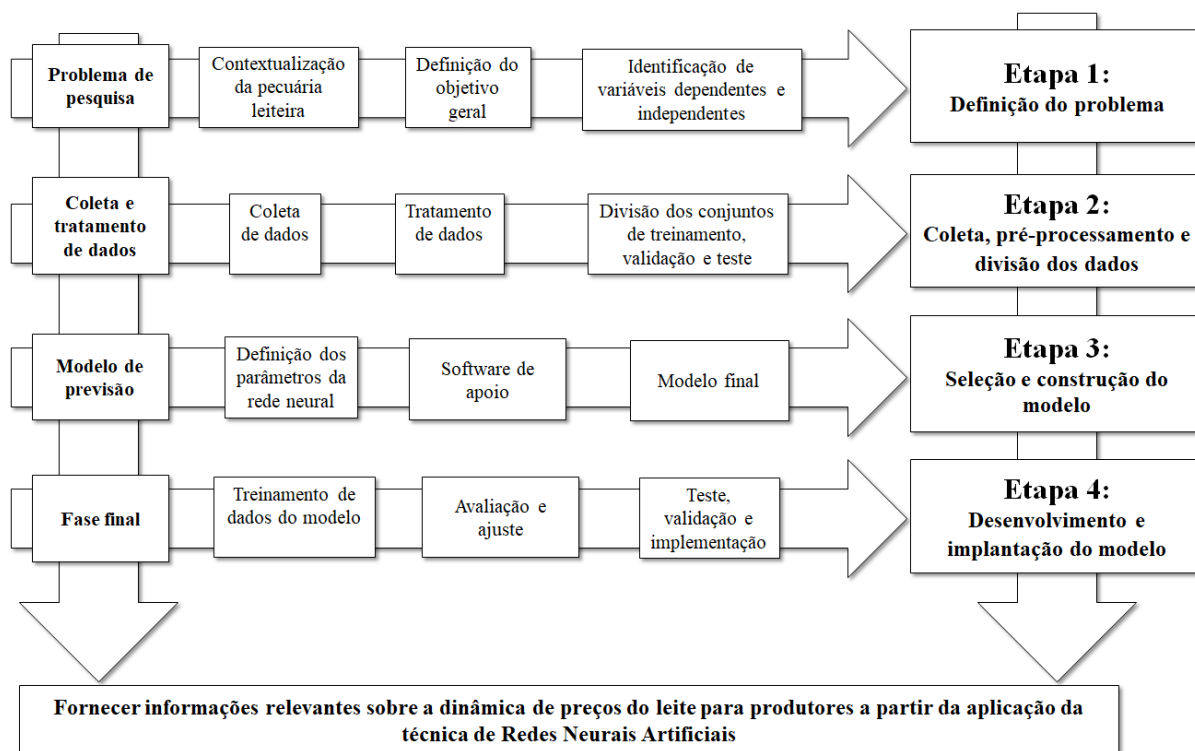


Fonte: Do autor (2024)

De acordo com a Figura 1, uma informação é fornecida à rede a partir da sua camada de entrada através de sinais. Logo, estes são absorvidos pelas camadas intermediárias e posteriormente codificados através de pesos sinápticos. Desta forma, as informações passam a ter uma representação própria pela rede neural (Braga; Ludermir; Carvalho, 2000; Silva, 2016). Por fim, os neurônios da camada de saída recebem as informações codificadas da última camada intermediária, e promovem um padrão de resposta para o conjunto de dados analisado (Silva, 2016). Neste estudo, a fim de gerar insights sobre a dinâmica de preços do leite para produtores

foi definido a priori um modelo conceitual em que se encontram todas as etapas de pesquisa seguidas, conforma apresentado na Figura 2.

Figura 2 - Modelo conceitual das etapas de pesquisa



Fonte: Do autor (2024)

A etapa 1 baseia-se na definição do problema de pesquisa. Nesta etapa foi realizada uma contextualização introdutória da pecuária leiteira, onde foram apresentados alguns temas estabelecidos no setor bem como possíveis lacunas de pesquisa na área de estudo. Esta etapa também se dedicou a definição do objetivo geral do estudo e, posteriormente, das variáveis originais consideradas. Assumindo que este estudo foi realizado a partir da construção de uma rede neural categórica, foram identificadas as variáveis originais independentes e a variável categórica dependente para o problema de pesquisa, conforme a Tabela 1.

Tabela 1 - Descrição de inputs e outputs da rede

(Continua)

Indicador	Unidade	Classificação	Descrição	Fonte
Preço_MG_Spot	R\$/L	Input	Cotação mensal do preço do leite spot em Minas Gerais	CEPEA
IFR(3)	Adimensional	Input	Índice de Força Relativa (3 meses)	*CEPEA
IFR(7)	Adimensional	Input	Índice de Força Relativa (7 meses)	*CEPEA

Tabela 1 - Descrição de inputs e outputs da rede

(Conclusão)

Indicador	Unidade	Classificação	Descrição	Fonte
IFR(14)	Adimensional	Input	Índice de Força Relativa (14 meses)	*CEPEA
MACD12_26	Adimensional	Input	Média Móvel Convergente e Divergente (12 e 26 meses)	*CEPEA
MACD5_12	Adimensional	Input	Média Móvel Convergente e Divergente (5 e 12 meses)	*CEPEA
IPCA	%	Input	Índice Nacional de Preços ao Consumidor Amplo	IBGE
Selic	%	Input	Taxa básica de juros	BCB
Preço_milho	R\$/saca	Input	Indicador do milho ESALQ/Bm&fBovespa	CEPEA
Preço_soja	R\$/saca	Input	Indicador da soja ESALQ/Bm&fBovespa - Paranaguá	CEPEA
Situação	Catagórica	Output	Variável dependente categórica (Aumento/Redução)	**

*Dados calculados com base no indicador Preço_MG_Spot.

**Obtido pela variação entre os meses atual e seguinte da variável Preço_MG_Spot.

Fonte: Do autor (2024)

As variáveis independentes do modelo corresponderam a Cotação mensal do preço do leite spot em Minas Gerais (Preço_MG_Spot), Indicador do milho ESALQ/Bm&fBovespa (Preço_milho) e Indicador da soja ESALQ/Bm&fBovespa – Paranaguá (Preço_soja) obtidos na base de dados do Centro de Estudos Avançados em Economia Aplicada (CEPEA). No caso das variáveis independentes Índice de Força Relativa (IFR3, IRF 7 e IFR14) e Média Móvel Convergente e Divergente (12 e 26 meses / 5 e 12 meses) estas foram extraídas a partir de cálculos da variável Preço_MG_Spot. As variáveis Índice Nacional de Preços ao Consumidor Amplo (IPCA) e Taxa básica de juros (Selic) foram extraídas das bases do Instituto Brasileiro de Geografia e Estatística (IBGE) e do Banco Central do Brasil (BCB), respectivamente. Os valores coletados para estas variáveis compreenderam dados mensais do período de 2012 a 2023. A variável dependente categórica (Aumento/Redução) (Situação) foi calculada pela variação entre os meses atual e seguinte da variável Preço_MG_Spot.

A etapa 2 corresponde às atividades de coleta, pré-processamento e divisão dos dados. Destaca-se a importância da atividade de pré-processamento para a geração de um modelo de maior acurácia e precisão, uma vez que a eliminação de outliers, valores ausentes e ruídos nos dados reduz a distorção dos resultados e a sobreposição de variáveis no modelo. A divisão do conjunto de dados neste estudo ocorreu em três subconjuntos distintos, a saber, treinamento, validação e teste. A validação ocorreu mediante o processo de validação cruzada em que há a separação aleatorizada de k subconjuntos de mesmo tamanho (k-fold) (Silva, 2016). O modelo

é treinado com $k-1$ subconjuntos e testado com o conjunto restante. Esse processo é repetido k vezes.

A etapa 3 contempla a seleção e construção do modelo de análise. Nesta etapa foi definido o tipo de rede neural utilizada, a quantidade de nós nas camadas de entrada, intermediárias e de saída, a função de ativação e o tipo de algoritmo de treinamento. A rede utilizada neste estudo seguiu o modelo de uma rede *perceptron* multicamadas com arquitetura feedforward. A quantidade de nós na camada de entrada equivale a quantidade de inputs da rede e a quantidade de nós na camada de saída corresponde ao número de outputs, neste caso, apenas um nó. Já a quantidade de nós das camadas intermediárias pode ser obtido pela média da quantidade de neurônios das camadas de entrada e saída.

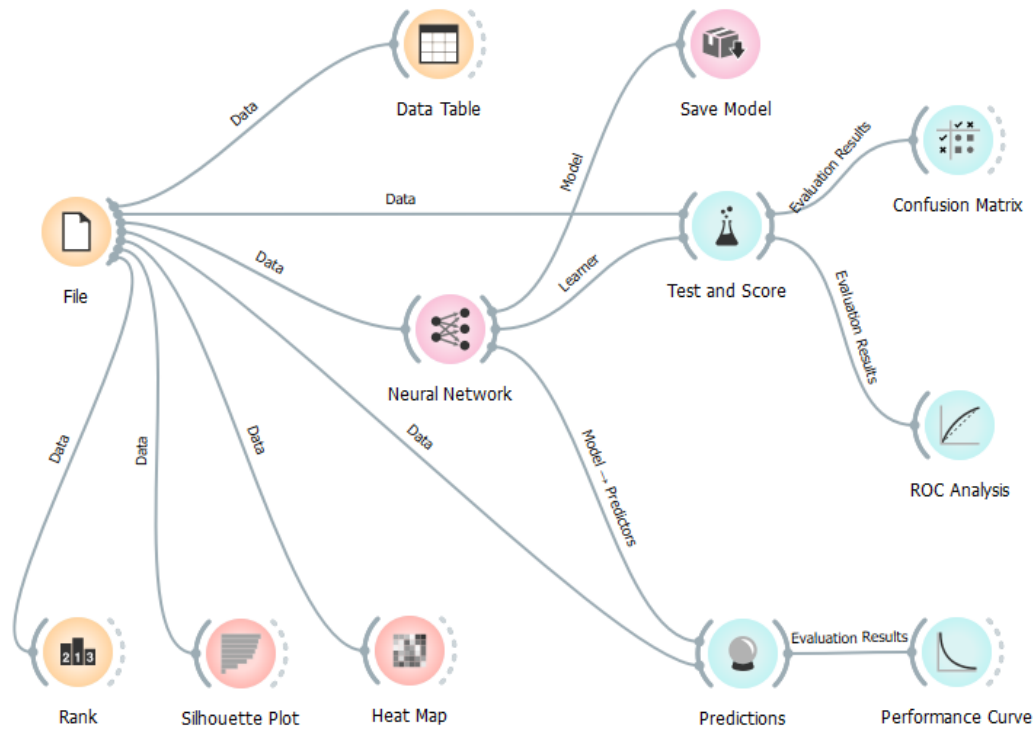
A função de ativação realiza a transformação não-linear ao longo do sinal de entrada da rede, neste caso, este estudo utilizou a função tangente hiperbólica. Já o algoritmo de treinamento utilizado foi o algoritmo *backpropagation*. O algoritmo de retropropagação (*backpropagation*) é pautado no cálculo automatizado do gradiente descendente, que percorre a rede em ambos os sentidos, para frente e para trás pelas camadas intermediárias, buscando diminuir a taxa de erro até convergir a melhor solução. Para tanto, o estudo se apoiou na utilização do *software R-Project 3.2.2* e *RStudio 2023.12.0+369* para compilação da rede. A Figura 3 contempla uma representação do modelo de rede neural proposto neste estudo.

Figura 3 - Algoritmo para o modelo de redes neurais artificiais

(Continua)

Figura 3 - Algoritmo para o modelo de redes neurais artificiais

(Conclusão)

*Construído com apoio do *software* Orange versão 3.37.0

Fonte: Do autor (2024)

A etapa 4 representa o desenvolvimento e implantação deste modelo. Nesta etapa ocorre o treinamento do modelo seguido da avaliação de desempenho e ajustes necessários. Logo, é possível a realização do teste, validação e implantação do modelo. Após o treinamento pelo algoritmo de retropropagação, se procedeu a avaliação de desempenho da rede neural. Acentua-se aqui as métricas de regressão (MSE – Erro quadrático médio; MAE – Erro absoluto médio; RMSE – Raiz do erro quadrático médio) e métricas de classificação (Acurácia; Precisão; Recall; F1-score) que podem ser utilizadas para aferição de desempenho da rede, conforme expressas em (1), (2), (3), (4), (5), (6) e (7).

$$MSE = \sum_{i=1}^n \frac{(y'_i - y_i)^2}{n} \quad (1)$$

$$MAE = \sum_{i=1}^n \frac{|y_i - y'_i|}{n} \quad (2)$$

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(y'_i - y_i)^2}{n}} \quad (3)$$

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (4)$$

$$Precisão = \frac{VP}{VP + FP} \quad (5)$$

$$Recall = \frac{VP}{VP + FN} \quad (6)$$

$$F1 - Score = \frac{2 * Precisão * Recall}{Precisão + Recall} \quad (7)$$

As equações (1), (2) e (3) representam métricas de regressão do modelo. Em (1) é calculado o erro quadrático médio. Em (2) é calculado o erro absoluto médio. Em (3) é calculado a raiz quadrada do erro quadrático médio. Nestes casos y'_i corresponde ao valor do output previsto como resultado de saída da rede, já y_i se refere ao valor real correspondente a este output. A acurácia (4) indica uma performance geral do modelo, ou seja, dentre todas as classificações, quantas o modelo classificou corretamente (Braga; Ludermir; Carvalho, 2000; Silva, 2016).


A precisão (5) indica dentre todas as classificações de classe Positivo que o modelo fez, quantas estão corretas. O recall/revocação/sensibilidade (6) indica dentre todas as situações de classe Positivo como valor esperado, quantas estão corretas. Já o F1-Score (7) corresponde à média harmônica entre as métricas de precisão e recall. A média harmônica é preferível, pois está muito mais próxima dos menores valores do que uma média aritmética simples. Ou seja, quando se tem um F1-Score baixo, é um indicativo de que ou a precisão ou o recall está baixo (Braga; Ludermir; Carvalho, 2000; Silva, 2016).

3 RESULTADOS

A fim de auxiliar a tomada de decisão de produtores e/ou gestores no setor da pecuária leiteira, este estudo avança com a construção de uma rede neural artificial para a realização de inferências sobre o preço do leite. Para tanto, foi desenvolvida uma rede *perceptron* de múltiplas camadas com arquitetura feedforward, em que são realizadas aproximações de funções complexas e a modelagem de relações entre as variáveis independentes e uma variável dependente.

As variáveis descritas na Tabela 1 corresponderam aos inputs e outputs da rede, sendo considerados 10 variáveis independentes numéricas e apenas 1 variável dependente categórica, uma vez que se trata de uma rede de caráter classificatório. Ou seja, a rede construída permite a previsão de aumento ou redução no preço do leite ao longo dos meses. A Figura 4 representa a arquitetura da rede neural construída neste estudo.

Figura 4 - Arquitetura de uma rede *perceptron* multicamadas



Fonte: Do autor (2024)

Em uma rede *perceptron* multicamadas, alguns fatores determinam o seu comportamento como, por exemplo, sua topologia (número de camadas ocultas e número de nós das camadas), seus pesos e termos de viés, bem como sua função de ativação. A priori, um neurônio oculto com n inputs realiza a soma ponderada de seus inputs, logo, uma função de ativação é aplicada à soma para gerar o output deste neurônio. Uma função sigmoide (em forma de S) é usada como função de ativação nos neurônios das camadas ocultas. Neste estudo, a função sigmoide foi representada por uma função tangente hiperbólica, por se tratar de uma

função contínua e diferenciável em todo seu domínio. Além disso, possui a característica de antissimetria (função ímpar) que contribui para melhorar o processo de convergência da rede durante o respectivo treinamento.

A rede construída se pautou em valores mensais considerando o período de novembro/2012 a outubro/2023. Logo, a etapa de treinamento ocorreu a partir da utilização de métodos de otimização para a identificação do ótimo global, neste caso, a combinação dos métodos de gradiente descendente conjugado (determinístico) e o método estocástico de recozimento simulado. Assim, quanto mais tempo de treinamento da rede, maior a probabilidade de encontrar um valor que corresponda ao mínimo global da função de erro. A Tabela 2 indica os parâmetros e resultados de treinamento da rede.

Tabela 2 - Resultados da etapa de treinamento da rede

Treinamento da rede	
Tipo de rede	<i>Perceptron</i> Multicamadas
Tempo de treinamento	2h
Número de casos de treinamento	98
Número de ensaios	126.954.518
Quantidade de nós	6
Nó da solução ótima	3
Quantidade de tentativas por nó	8.000.000
Acurácia (%)	94,89%
Precisão (%)	94,33%
Recall (%)	96,15%
F1-Score (%)	95,23%
MSE	0,0510
MAE	0,1036
RMSE	0,2258

Fonte: Do autor (2024)

De acordo com os resultados de treinamento, para a rede *perceptron* multicamadas desenvolvida, a solução ótima foi encontrada no terceiro nó, com uma quantidade de seis nós nas camadas ocultas. Foi estabelecido um número de 8.000.000 de tentativas por nó e o número de casos de treinamento foi igual a 98. Se tratando das métricas de regressão a rede apresentou um erro quadrático médio de 0,0510, um erro absoluto médio de 0,1036 e um RMSE de 0,2258. O que indica um baixo viés para a etapa de treinamento da rede.

Com relação às métricas de classificação, a rede desenvolvida apresentou uma acurácia de 94,89%. Isso indica que 94,89% dos casos preditos pela rede foram corretos. A métrica de precisão indicou um acerto de 94,33% dentre todas as classificações de classe “Aumento” que

o modelo fez. A sensibilidade ou recall revelou um acerto de 96,15% para situações de classe “Aumento” como valor esperado. Por fim, o F1-score correspondeu à média harmônica entre as métricas de precisão e recall, obtendo o valor de 95,23% para casos de treinamento. Prosseguindo a análise, a Tabela 3 representa os parâmetros e resultados da etapa de teste da rede.

Tabela 3 - Resultados da etapa de teste da rede

Teste da rede	
Tipo de rede	<i>Perceptron</i> Multicamadas
Número de casos de teste	122
Quantidade de nós	6
Nó da solução ótima	3
Quantidade de tentativas por nó	8.000.000
Acurácia (%)	87,70%
Precisão (%)	86,57%
Recall (%)	90,63%
F1-Score (%)	88,55%
MSE	0,1229
MAE	0,2489
RMSE	0,3505

Fonte: Do autor (2024)

Na etapa de teste, há o cálculo final dos indicadores de regressão e classificação da rede. Neste caso, a acurácia foi obtida pela razão entre o somatório de acertos da rede e o número de casos de teste ($107/122 = 87,70\%$). O indicador de precisão se refere ao número de acertos obtidos na categoria de verdadeiros positivos, ou seja, a taxa de acertos da rede por categoria. Neste caso, a rede apresentou uma precisão de 86,57% para a categoria de “Aumento” ($58/67 = 86,57\%$). A sensibilidade ou recall apresentou um valor de 90,63% e o F1-score de 88,55%.

Já os indicadores de regressão apresentaram valores próximos comparados a etapa de treinamento, com MSE na ordem de 0,1229, MAE de 0,2489 e RMSE de 0,3505. A ocorrência de altos valores para acurácia tanto na etapa de treinamento quanto de teste indicam a proximidade da solução ótima do modelo. Além disso, indica que o modelo não sofre a ocorrência de sobreajuste (*overfitting*) ou subajuste (*underfitting*), pois tem um bom desempenho para novos casos de teste, e apresenta um nível de complexidade compatível com o conjunto de dados, o que permite o alcance de bons índices de assertividade para as métricas de classificação. A fim de ilustrar o nível de assertividade do modelo, a Tabela 4 apresenta a matriz de confusão da rede.

Tabela 4 - Matriz de confusão

		Predito	
		Aumento	Redução
Real	Aumento	58	6
	Redução	9	49

Fonte: Do autor (2024)

A matriz de confusão representa o comportamento do modelo de previsão em relação a cada classe e contrasta os resultados preditos à realidade analisada. A partir da matriz de confusão podem ser calculadas as métricas de classificação: acurácia, precisão, recall e F1-score. O modelo também pode ser beneficiado pela matriz de confusão a partir da detecção mais rápida de possíveis erros e problemas de *overfitting* e *underfitting*, indicando a necessidade de aumento do conjunto de dados ou ajustes no modelo. Através da matriz de confusão é possível avaliar a taxa de sensibilidade (verdadeiros positivos) e a taxa de especificidade (verdadeiros negativos). Sendo assim, para a rede desenvolvida, a matriz de confusão indicou dentre os 122 casos de teste, 58 verdadeiros positivos, 9 falsos positivos, 6 falsos negativos e 49 verdadeiros negativos.

Por fim, a etapa de predição foi realizada conforme a Tabela 5. Neste caso, os resultados correspondem à amostra de 10 meses considerados para predição da rede, período correspondente de janeiro à outubro de 2023. Deste intervalo, a rede alcançou um total de 7 acertos em 10. Vale ressaltar que a predição da variável dependente categórica ocorreu a partir da variação dos preços do input Preço_MG_Spot entre o mês seguinte e o atual. O preço do leite spot corresponde ao preço praticado entre empresas fornecedoras do leite com entrega imediata e pagamento à vista.

Tabela 5 - Resultados da etapa de previsão para 10 casos

Mês/Ano	Situação Real	Predição
jan/23	Aumento	Aumento
fev/23	Aumento	Aumento
mar/23	Redução	Aumento
abr/23	Redução	Redução
mai/23	Redução	Redução
jun/23	Redução	Redução
jul/23	Redução	Redução
ago/23	Redução	Redução
set/23	Redução	Aumento
out/23	Redução	Aumento

Fonte: Do autor (2024)

Acentua-se aqui que os resultados apresentados na etapa de predição são condizentes ao nível de complexidade do modelo construído e indicam uma boa capacidade de previsão para a variável categórica dependente, identificando períodos de aumento ou redução do preço do leite.

4 DISCUSSÃO

A pecuária leiteira é um setor que contribui para a economia global, desenvolvimento rural e segurança alimentar (Arvidsson Segerkvist et al., 2020). Isso porque a produção do leite envolve uma sequência de operações de produção, manejo e gerenciamento que garante a geração de empregos e renda à pequenos, médios e grandes produtores (Talukder et al., 2021). Além disso, a intensificação da demanda por produtos lácteos pode impactar no desenvolvimento infraestrutural das propriedades. Por se tratar de uma cadeia de produção abrangente, o setor lácteo está associado a alimentação da maioria da população (Arvidsson Segerkvist *et al.*, 2020). Neste sentido, o leite representa um produto de alto valor nutricional e a base para a dieta de crianças e idosos, especialmente para as classes de maior vulnerabilidade econômica (Maina et al., 2020).

A volatilidade de preços é um fator recorrente na cadeia produtiva do leite (Arvidsson Segerkvist *et al.*, 2020; Maina *et al.*, 2020). Questões climáticas, políticas econômicas, tecnologia, mudanças dos padrões de consumo correspondem a alguns fatores de impacto no preço do leite. Logo, trabalhar alternativas de contorno a estas oscilações pode beneficiar produtores e/ou gestores no planejamento de sua produção. Nesse aspecto, este estudo de previsão de aumentos ou reduções no preço do leite confere a estes produtores informações sobre fatores de impacto na produção, e sobretudo, na comercialização do leite. Isso permite que estes produtores possam se antecipar às oscilações de mercado e garantir sua permanência no setor.

Estudos de previsão no âmbito da pecuária leiteira têm sido realizados a fim de gerar diferentes contribuições para o setor (Achour *et al.*, 2020; Liseune *et al.*, 2021; Tassinari *et al.*, 2021; Zheng *et al.*, 2023). A utilização de algoritmos de machine learning é uma característica destes estudos, em que são observadas a construção de redes neurais artificiais para a previsão, classificação e reconhecimento de imagens por exemplo. A capacidade de previsão das redes neurais artificiais se baseia na arquitetura de rede utilizada bem como nos processos anteriores de treinamento e teste. Uma rede neural de alto desempenho também apresenta alta capacidade de generalização, ou seja, ela se adapta bem com a inserção de novos dados de entrada e gera bons resultados.

Acentua-se aqui os estudos de Sanzogni e Kerr (2001), Shahinfar et al. (2012), Ankinakatte et al. (2013), Zhang (2020) e Vasafi et al. (2021) sobre a aplicação de redes neurais artificiais como técnica de apoio para o controle de qualidade de produtos lácteos. A utilização de redes neurais artificiais neste estudo apresentou convergência com as metodologias seguidas por estes autores. A priori, o modelo de redes descrito por Shahinfar et al. (2012), Ankinakatte

et al. (2013), Zhang (2020) e Vasafi et al. (2021) também utiliza resíduos individuais ao invés de pontuações fatoriais. Isso permite um acompanhamento do viés como um parâmetro a ser minimizado. Cada nó ou neurônio do modelo apresenta um valor individual de viés, sendo a etapa de treinamento essencial para a busca do mínimo global desta variável. Sanzogni e Kerr (2001) realizaram um estudo de previsão da produção de leite na Austrália. O uso das redes neurais nesse caso indicou a quantidade de leite produzido em cada uma das regiões do país analisadas.

Liseune *et al.* (2021) realizaram um estudo de previsão da curva de lactação para rebanhos leiteiros. Os autores propõem uma nova metodologia de cálculo pautada nos valores de lactação registrados no ciclo de produção anterior do animais. Assim como este estudo, Liseune *et al.* (2021) buscaram contribuições relacionadas a implementação de boas práticas de manejo, promovendo a antecipação o planejamento de produtores e/ou gestores. No entanto, a diferença é que Liseune *et al.* (2021) se dedicaram ao aspecto de previsão da produção, já este estudo se baseou em aspectos econômicos, relacionados à classificação do comportamento do preço do leite ao longo dos meses.

Tassinari *et al.* (2021), Achour *et al.* (2020) e Zheng *et al.* (2023) apresentaram convergências em seus estudos sobre monitoramento de rebanhos leiteiros. Estes estudos utilizaram algoritmos de machine learning para a identificação da posição dos animais. Na prática, são estudos que contribuem para o aumento da eficiência da produção do leite, pois viabilizam o diagnóstico precoce de doenças nos animais, bem como um acompanhamento intensivo do ciclo reprodutivo destes. Também são estudos que promovem a adoção de melhores práticas de manejo e bem-estar animal. Trata-se de estudos pautados na utilização de redes para o reconhecimento de imagens, diferentemente deste estudo em que foi construída uma rede de classificação do preço do leite.

Atalan (2023) também realizou um estudo de previsão do preço do leite. No estudo, o autor compara diferentes algoritmos de machine learning para a realização da previsão. O algoritmo Random forest obteve os melhores resultados de previsão do modelo. Trata-se de um estudo com objetivo de comparação metodológica. Este estudo também se difere por ser pautado em uma rede de previsão, e não de classificação. Frente a isso, o presente estudo foi baseado na construção de uma rede neural para auxiliar a tomada de decisão de produtores, de modo a informar sobre o preço do leite spot. Constatou-se que a técnica de redes neurais artificiais é um ponto de apoio para gestores e produtores neste contexto, o que dá maior liberdade para a negociação de matéria-prima de menor custo e potencialização da margem de lucro.

No que tange às variáveis utilizadas na construção da rede neural neste estudo, foram adotadas 11 variáveis, sendo 10 independentes numéricas e 1 dependente categórica. Destas, 6 variáveis derivaram do preço observado para o leite spot. Vale ressaltar a preferência de uso da série histórica do preço do leite spot em relação a do preço do leite pago ao produtor, haja vista que se trata de uma base de dados mais completa, embora ambas apresentem alta correlação. As variáveis Índice de Força Relativa (3 meses), Índice de Força Relativa (7 meses) e Índice de Força Relativa (14 meses) tratam da mensuração do movimento de variação dos preços do leite nos respectivos períodos, e indicam de forma objetiva as melhores épocas para compra e venda do leite. Já a Média Móvel Convergente e Divergente (12 e 26 meses) e Média Móvel Convergente e Divergente (5 e 12 meses) representam as médias móveis exponenciais do preço do leite spot, que também auxiliam nas análises de médio e longo prazos.

Neste estudo para a etapa de treinamento a escolha de utilização do algoritmo de retropropagação foi assertiva, pois permitiu o maior ajuste do modelo aos dados fornecidos. Além disso, a divisão dos dados em subconjuntos para a realização da validação cruzada conferiu robustez a análise, evitando possíveis problemas de sobreajuste (*overfitting*). Ressalta-se aqui o desempenho do modelo na etapa de teste, o que justificou a capacidade do modelo de generalizar para novos dados. A etapa de predição confirmou a concordância entre o nível de complexidade do modelo frente o conjunto de dados amostrados.

Os resultados apresentados pela rede neste estudo podem ser desdobrados através de uma matriz de classificação ou confusão em que são expostos os números de ocorrências por categoria de análise. Neste caso, foram analisadas as ocorrências para duas categorias (“Aumento” e “Redução”). A partir disso é viabilizado o cálculo da taxa de verdadeiros positivos e de falsos positivos, ou seja, a acurácia e viés respectivamente. A acurácia permite uma análise do nível de sensibilidade do modelo, já a precisão tem relação com o nível de especificidade do modelo. Ademais, neste estudo observou-se que a inserção de novos indicadores na rede como variáveis independentes numéricas, não necessariamente iria aumentar a acurácia do modelo. Vale ressaltar que variáveis altamente correlacionadas também apresentaram pouco impacto no aumento da acurácia e redução de viés.

Com base nos resultados apresentados, as implicações políticas deste estudo permeiam avanços nas políticas agrícolas, isso porque este estudo pode auxiliar os governos na definição de subsídios e programas de apoio a produtores em épocas de baixa do preço do leite, promovendo a maior permanência de pequenos e médios produtores na atividade. Também podem ser desenvolvidas políticas de controle e planejamento da produção, pois este estudo

gera informações relevantes sobre o preço futuro do leite, podendo evitar o excesso de oferta ou escassez.

Na perspectiva comercial, a previsão do preço do leite pode impactar na implementação de políticas comerciais, com a definição de novas tarifas de importação ou cotas de exportação, a fim de obter maior controle do abastecimento do mercado nacional e equilíbrio no comércio internacional de produtos lácteos. Considerando que se trata de um mercado volátil, onde fatores climáticos tendem a influenciar a produção do leite, a previsão do preço do leite pode auxiliar gestores na implementação de mecanismos de controle de preços, beneficiando consumidores finais. Além disso, a questão da transparência de mercado pode ser melhor alcançada mediante este estudo de previsão, visto que a divulgação de possíveis aumentos ou reduções do preço pode reduzir a especulação e conferir maior estabilidade de mercado.

Ainda na proposta de beneficiamento de consumidores finais, este estudo pode subsidiar o desenvolvimento de programas de assistência alimentar. Caso ocorra previsões de aumento do preço do leite, estes programas podem ser realizados a fim de garantir o acesso da população mais vulnerável economicamente ao leite e seus derivados. Trata-se de políticas que promovem o bem-estar social e a segurança alimentar. Neste contexto, a criação de estoques de regulação representa uma alternativa para o equilíbrio de mercado e garantia da oferta.

Por fim, a questão ambiental pode ser impactada com as informações de aumentos ou reduções nos preços futuros do leite. Isso porque a alta do preço pode influenciar produtores a investir em boas práticas de manejo pautadas em tecnologias verdes como biodigestores e sistemas de reutilização de água, por exemplo. Também é viabilizada a realização de ajustes na dieta dos animais para a redução da emissão de metano na atmosfera. Cabe lembrar a possibilidade de realização de sistemas de rotação de pastagens, preservando a saúde do solo e biodiversidade.

5 CONSIDERAÇÕES FINAIS

A pecuária leiteira é um setor abrangente que beneficia diferentes classes populacionais com a geração de renda e empregos. Também é um setor que impacta na garantia da segurança alimentar de populações vulneráveis. No entanto, alguns aspectos de cunho econômico e ambiental dificultam a permanência de pequenos e médios produtores no setor. A volatilidade de preços corresponde a uma das principais causas de evasão destes produtores. Por isso, este estudo avançou na perspectiva de gerar insights sobre a dinâmica de preços do leite a partir da utilização de uma rede neural artificial de classificação. Esta rede foi capaz de indicar aumentos ou reduções no preço mensal do leite.

As contribuições práticas deste estudo estiveram relacionadas a uma gestão mais eficiente e ao melhor planejamento de produtores. Isso porque ao obter informações antecipadas sobre as oscilações da dinâmica de preços do leite, os produtores têm condições de tomar decisões mais informadas sobre sua produção, técnicas de manejo e investimentos em infraestrutura. Este estudo também pode indicar o melhor período para a obtenção de créditos e financiamentos. No âmbito comercial, este estudo pode fornecer insights para setores de atacado e varejo, promovendo uma política de preços mais competitiva para os consumidores.

Já as contribuições teóricas correspondem ao avanço na modelagem preditiva no contexto da pecuária leiteira. Este estudo também contribui para a identificação de variáveis de maior impacto no preço do leite. Além disso, os resultados apresentados neste estudo quando associados a teorias econômicas pode oferecer informações sobre a dinâmica do mercado, elasticidade de preços, comportamento do consumidor. Em suma, este estudo também contribui como um incentivo na realização de novos estudos no campo da inteligência artificial aplicada a pecuária leiteira.

Dentre as implicações políticas do estudo podem ser mencionadas a criação de políticas agrícolas e subsídios de apoio a pequenos e médios produtores em períodos de baixa dos preços. Além disso, o desenvolvimento de políticas de acesso da população vulnerável, a fim de garantir a manutenção de seu poder de compra em períodos de alta do preço do leite. Este estudo ainda pode subsidiar a realização de investimentos em infraestrutura e desenvolvimento rural nas propriedades. No âmbito sustentável, também pode impactar na adesão de produtores à adoção de tecnologias verdes, otimização do consumo de recursos naturais e redução da emissão de gases de efeito estufa.

O estudo apresentou algumas limitações. Neste sentido pode ser ressaltado o tempo de treinamento da rede e a necessidade de recursos computacionais robustos. O estudo também se

ateve a construção de uma agenda de estudos futuros. Frente a isso, é sugerida a replicação deste estudo para um conjunto amostral maior, que considere variáveis climáticas no modelo. Também se sugere a adoção de outros algoritmos de machine learning para a previsão da volatilidade do preço do leite, a fim de gerar insights comparativos entre diferentes técnicas.

REFERÊNCIAS

- ACHOUR, Brahim et al. Image analysis for individual identification and feeding behaviour monitoring of dairy cows based on Convolutional Neural Networks (CNN). **Biosystems Engineering**, v. 198, p. 31-49, 2020.
- ANKINAKATTE, S. et al. Predicting mastitis in dairy cows using neural networks and generalized additive models: A comparison. **Computers and electronics in agriculture**, v. 99, p. 1-6, 2013.
- ARVIDSSON SEGERKVIST, Katarina *et al.* Research on environmental, economic, and social sustainability in dairy farming: A systematic mapping of current literature. **Sustainability**, v. 12, n. 14, p. 5502, 2020.
- ATALAN, Abdulkadir. Forecasting drinking milk price based on economic, social, and environmental factors using machine learning algorithms. **Agribusiness**, v. 39, n. 1, p. 214-241, 2023.
- BRAGA, Antônio de Pádua; LUDERMIR, Teresa Bernarda; CARVALHO, André Carlos Ponce de Leon Ferreira de. *Redes neurais artificiais: teoria e aplicações*. 2000.
- CABRERA, Victor E.; FADUL-PACHECO, Liliana. Future of dairy farming from the Dairy Brain perspective: Data integration, analytics, and applications. **International Dairy Journal**, v. 121, p. 105069, 2021.
- FEIL, Alexandre André *et al.* Sustainability performance of small and medium dairy enterprises in Brazil. **Sustainable Production and Consumption**, v. 39, p. 301-310, 2023.
- GORI MAIA, Alexandre *et al.* Climate resilience programmes and technical efficiency: evidence from the smallholder dairy farmers in the Brazilian semi-arid region. **Climate and Development**, v. 14, n. 3, p. 197-207, 2022.
- IBGE. Rebanhos e valor dos principais produtos de origem animal foram recordes em 2022. 2023. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/37937-rebanhos-e-valor-dos-principais-produto-de-origem-animal-foram-recordes-em-2022#:~:text=A%20produ%C3%A7%C3%A3o%20de%20leite%20de,milh%C3%B5es%20de%20cabe%C3%A7..> Acesso em: 28 fev. 2024.
- JEBARI, Asma *et al.* Effect of dairy cattle production systems on sustaining soil organic carbon storage in grasslands of northern Spain. **Regional Environmental Change**, v. 22, n. 2, p. 67, 2022.
- LAU, Samantha *et al.* Development of a Monte Carlo simulation model to predict pasteurized fluid milk spoilage due to post-pasteurization contamination with gram-negative bacteria. **Journal of Dairy Science**, v. 105, n. 3, p. 1978-1998, 2022.
- LEITGEB, Friedrich *et al.* Comparing the ecological sustainability performance of organic farms and conventional production in Austria using the SMART farm tool and Monte Carlo simulation. **Organic Agriculture**, p. 1-19, 2023.

- LISEUNE, Arno et al. Predicting the milk yield curve of dairy cows in the subsequent lactation period using deep learning. **Computers and Electronics in Agriculture**, v. 180, p. 105904, 2021.
- LIU, Shenhe *et al.* Transcriptome analysis reveals potential regulatory genes related to heat tolerance in holstein dairy cattle. **Genes**, v. 11, n. 1, p. 68, 2020.
- MAINA, Florence *et al.* Factors influencing economic efficiency of milk production among small-scale dairy farms in Mukurweini, Nyeri County, Kenya. **Tropical animal health and production**, v. 52, p. 533-539, 2020.
- MARTINELLI, Raiane Real *et al.* Horizontal collaborations and the competitiveness of dairy farmers in Brazil. **Journal of Co-operative Organization and Management**, v. 10, n. 2, p. 100183, 2022.
- ROMANIUK, Waław *et al.* Biomass energy technologies from innovative dairy farming systems. **Processes**, v. 9, n. 2, p. 335, 2021.
- RUVIARO, Clandio Favarini *et al.* Life cycle cost analysis of dairy production systems in Southern Brazil. **Science of the Total Environment**, v. 741, p. 140273, 2020.
- SANZOGNI, Louis; KERR, Don. Milk production estimates using feed forward artificial neural networks. **Computers and electronics in agriculture**, v. 32, n. 1, p. 21-30, 2001.
- SHAHINFAR, Saleh et al. Prediction of Breeding Values for Dairy Cattle Using Artificial Neural Networks and Neuro-Fuzzy Systems. **Computational and Mathematical Methods in Medicine**, v. 2012, n. 1, p. 127130, 2012.
- SILVA, I. N. Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas. Fundamentos Teóricos e Aspectos Práticos, Editora : Artliber; 2ª edição, 2016.
- TALUKDER, Byomkesh *et al.* Multi-indicator supply chain management framework for food convergent innovation in the dairy business. **Sustainable Futures**, v. 3, p. 100045, 2021.
- TASSINARI, Patrizia et al. A computer vision approach based on deep learning for the detection of dairy cows in *free stall* barn. **Computers and Electronics in Agriculture**, v. 182, p. 106030, 2021.
- VASAFI, Pegah Sadeghi et al. Anomaly detection during milk processing by autoencoder neural network based on near-infrared spectroscopy. **Journal of Food Engineering**, v. 299, p. 110510, 2021.
- YU, Zetian *et al.* Production Efficiency of Raw Milk and Its Determinants: Application of Combining Data Envelopment Analysis and Stochastic Frontier Analysis. **Agriculture**, v. 13, n. 2, p. 370, 2023.
- ZHANG, Zheng-Yong. Rapid discrimination of cheese products based on probabilistic neural network and Raman spectroscopy. **Journal of Spectroscopy**, v. 2020, n. 1, p. 8896535, 2020.

ZHENG, Zhiyang et al. Cows' legs tracking and lameness detection in dairy cattle using video analysis and Siamese neural networks. **Computers and Electronics in Agriculture**, v. 205, p. 107618, 2023.

TERCEIRA PARTE – CONSIDERAÇÕES FINAIS

CONSIDERAÇÕES FINAIS

A pecuária leiteira tem participação no contexto da produção global de alimentos. Trata-se de um setor diverso que integra produtores de diferentes escalas de produção. O avanço de boas práticas de produção de caráter sustentável aliadas ao bem-estar animal configuram alguns dos temas de interesse da pecuária de leite moderna. No entanto, este setor tem sido impactado pela alta volatilidade de mercado, decorrente de aspectos de consumo, questões climáticas, sazonalidade de preços, entre outros. Deste modo, este estudo avaliou o desempenho das regiões produtoras de leite no Brasil, buscando oferecer um modelo de gestão de desempenho amparado por diferentes técnicas, a saber, PCA, DEA, SMC e RNA.

As contribuições do estudo foram diversas, a priori, o estudo promove a melhoria da eficiência operacional de propriedades leiteiras. Também permite que produtores tomem decisões mais informadas, de modo a otimizarem o consumo de seus recursos em suas propriedades. O estudo ainda contribui para ampliar as possibilidades de tomada de decisão no âmbito da gestão de operações. Por fim, é um estudo que fornece subsídios para o desenvolvimento de estratégias de mitigação de riscos no setor agropecuário, e promove a redução de desigualdade no setor e desenvolvimento rural.

Este estudo apresentou como resultados a geração de dois artigos, sendo o primeiro direcionado a gestão de eficiência nas propriedades leiteiras, identificação de propriedades ineficientes e indicação de benchmarks determinísticos e probabilísticos. Já o segundo artigo forneceu informações relevantes sobre a dinâmica de preço do leite para produtores a partir da aplicação da técnica de Redes Neurais Artificiais. Neste sentido, os artigos se relacionam com a geração de resultados complementares sobre o consumo orientado de recursos, de forma a otimizar as entradas do modelo de gestão de desempenho proposto, e maximização de receitas ou saídas do modelo, a partir da identificação de melhores épocas de comercialização do leite.

Espera-se que este estudo forneça uma base de conhecimento sólida do setor para as partes interessadas, bem como ampare a tomada de decisão de produtores e/ou gestores em suas propriedades. Além disso, espera-se que os resultados de ambos os artigos deste estudo possam ser utilizados de forma complementar em um modelo unificado de gestão de melhorias de desempenho na pecuária leiteira de diferentes regiões do mundo.