



De 11 a 14 - NOVEMBRO DE 2024

**Inteligência Artificial
na Gestão de Operações:**
Limitações e possibilidades



PREVISÃO DO COMPORTAMENTO DOS PREÇOS DO LEITE USANDO MODELOS DE REDES NEURAIS ARTIFICIAIS (RNAs)

EUNICE HENRIQUES PEREIRA VILELA – e-vilela@ufu.br
UNIVERSIDADE FEDERAL DE UBERLÂNDIA - UFU

ANTONIO SÉRGIO TORRES PENEDO - drpenedo@gmail.com
UNIVERSIDADE FEDERAL DE UBERLÂNDIA - UFU

ÁREA: 7. GESTÃO ECONÔMICA
SUBÁREA: 7.4 – GESTÃO DE RISCOS

RESUMO: CONSIDERANDO A IMPORTÂNCIA ECONÔMICA E SOCIAL DA PRODUÇÃO DE LEITE PARA A REGIÃO DO TRIÂNGULO MINEIRO E ALTO PARANAÍBA(TMAP)E O FATO DO LEITE SER CONSIDERADO UMA DAS COMMODITIES AGRÍCOLAS MAIS VOLÁTEIS DO MERCADO INTERNACIONAL, ESTA PESQUISA SE PROPÔS A EXAMINAR O COMPORTAMENTO DOS PREÇOS DO LEITE NA REGIÃO E, MAIS ESPECIFICAMENTE, DESENVOLVER UM MODELO DE PREVISÃO DESTES COMPORTAMENTO. A PARTIR DE UMA INVESTIGAÇÃO DOS PRINCIPAIS FATORES QUE PODERIAM INFLUENCIAR O COMPORTAMENTO DOS PREÇOS DO LEITE NA REGIÃO, BUSCOU-SE CONSTRUIR UM MODELO DE PREVISÃO DE PREÇOS, BASEADO EM REDES NEURAIS ARTIFICIAIS (RNAs). DENTRE OS DIFERENTES MODELOS TESTADOS, AQUELE QUE APRESENTOU O MELHOR DESEMPENHO PREDITIVO, COM UM MSE DE 0,009 E UM R^2 0,1946, INCLUIU COMO VARIÁVEIS DE ENTRADA OS PREÇOS DO LEITE NOS ESTADOS UNIDOS E NO URUGUAI, DO LEITE PASTEURIZADO E DO QUEIJO MUÇARELA, DA CARNE BOVINA E DA ENERGIA RURAL, E AS TAXAS DE CÂMBIO, O ÍNDICE GERAL DE PREÇOS DE MERCADO (IGPM), E A PRECIPITAÇÃO MENSAL NA REGIÃO, CONSIDERANDO UMA DEFASAGEM DE TRÊS MESES. A PARTIR DESSES RESULTADOS FOI POSSÍVEL CONCLUIR QUE A INCLUSÃO DE DIFERENTES VARIÁVEIS POSSIBILITADA PELO MODELO REDES NEURAIS ARTIFICIAIS, BEM COMO SEU MECANISMO DE APRENDIZAGEM PERMITE QUE ESTE TENHA UMA BOA CAPACIDADE DE PREVER TENDÊNCIAS DE ELEVAÇÃO OU REDUÇÃO NOS PREÇOS DO LEITE.

PALAVRAS-CHAVES:PECUÁRIA LEITEIRA; REDES NEURAIS ARTIFICIAIS; PREVISÃO DE PREÇOS.

1. INTRODUÇÃO

A volatilidade dos preços dos produtos agropecuários é uma questão relevante para países com grandes setores agrícolas, como é o caso brasileiro. Oscilações dos preços desestabilizam o mercado econômico e afetam as decisões de gestão de produtores, intermediários e consumidores.

Atualmente, leite é considerado como uma das *commodities* agrícolas mais voláteis no mercado internacional. Tal volatilidade pode ser resultado de diversos fatores como clima, inflação, oscilações na oferta e demanda, renda do consumidor e política governamental, bem como das preferências dos consumidores (Acosta; Ihle; Robles, 2014; Borawski et al., 2020)

A volatilidade impõe desafios adicionais ao planejamento de negócios, ao pagamento de dívidas e, até a solvência dos negócios. Sendo causa de grande parte das mudanças estruturais que vem ocorrendo no setor, visto que preços mais voláteis resultam em uma maior taxa de saída dos produtores da atividade e tornam as expansões mais arriscadas para as propriedades, principalmente as de pequeno e médio porte (Zimmermann; Heckelei, 2012).

Assim, o aumento na volatilidade dos preços do leite não é mais percebido como um fenômeno temporário, mas como a nova tendência dos mercados globais. Levantando sérias preocupações, não apenas entre produtores e consumidores, mas também entre os formuladores de políticas que buscam projetar medidas de política diferentes das ferramentas tradicionais de mercado para diminuir as oscilações de preços (FAO, 2010; Acosta; Ihle; Robles, 2014). Conforme Norton (2004), garantir um nível de preços competitivo na porta da fazenda é uma das chaves para o crescimento agrícola e, portanto, para a redução da pobreza.

Para tentar contornar as dificuldades impostas, é necessário que, cada vez mais, produtores e formuladores de políticas públicas busquem aprimorar seu conhecimento a respeito do funcionamento dos mercados, bem como do comportamento dos preços. Assim, o estudo e conhecimento a respeito do comportamento dos preços, bem como dos fatores que o influenciam é importante tanto para o desenho de políticas públicas apropriadas para reduzir o nível de volatilidade dos preços do leite, quanto para subsidiar a tomada de decisão em condições incertas, e que pode influenciar significativamente os retornos dos participantes do mercado de leite e derivados (Acosta; Ihle; Robles, 2014; Hansen; Li, 2017; Costa-Font; Revoredo-Giha, 2017).

Nessa perspectiva, a negociação em mercados futuros vem sendo defendida como uma possível e interessante ferramenta de gerenciamento de risco para agricultores e processadores. Siqueira et al. (2008) avaliaram a viabilidade da introdução de contratos

futuros de leite no Brasil, analisando atributos específicos de *commodities* e aspectos relacionados ao mercado do leite, e verificaram que aproximadamente 92% dos produtores tinham interesse em adotar contratos futuros de leite como ferramentas de gerenciamento de risco de preço. Nesse sentido, em maio de 2021, a Comissão Nacional de Pecuária de Leite da Confederação da Agricultura e Pecuária do Brasil (CNA) se reuniu para discutir as oportunidades do mercado futuro como uma opção de comercialização aos produtores que precisam controlar a gestão de riscos, e a falta de previsibilidade do preço do leite pago ao produtor (CNA, 2021).

No entanto, para que os produtores possam negociar neste tipo de mercado, é necessário que consigam fazer estimativas de preços à longo prazo de modo a subsidiar a tomada de decisão. Hansen e Li (2017), afirmam que compreensão do comportamento dos preços é, nesses casos, um elemento crítico que pode influenciar significativamente os retornos dos participantes do mercado de laticínios. Com este intuito, o interesse por modelos de previsão de preços tem se tornado crescente.

Considerando tal cenário e a importância da produção do leite para a região do Triângulo Mineiro e Alto Paranaíba, este trabalho se propõe a desenvolver um modelo de previsão do comportamento dos preços do leite na região. Para tanto foi utilizado um modelo de Redes Neurais Artificiais (RNAs), e testados arranjos de variáveis que incluem os preços do leite no mercado internacional, os preços dos principais derivados do leite comercializados no Brasil e os preços das principais *commodities*, agrícolas e não agrícolas, que foram identificadas, com base no levantamento da literatura como capazes de afetar os preços do leite.

O trabalho, além desta introdução, está dividido em 5 sessões. Na segunda sessão é apresentado o referencial teórico utilizado para a construção do trabalho. Na terceira sessão são apresentados os aspectos metodológicos pertinentes a elaboração da pesquisa; na quarta sessão são abordados os resultados obtidos; e na quinta e última sessão são tecidas as considerações finais sobre os achados da pesquisa.

2. REFERENCIAL TEÓRICO

2.1. Fatores que influenciam o comportamento dos preços do leite

Um dos principais fatores apontados pela literatura com capaz de influenciar os preços do leite em determinada região são os preços do leite no mercado internacional. Os trabalhos de Engler e Nahuelhual (2003), Acosta, Ihle e Robles (2014), Labra-Hernández, Cabas-Monje

e Velasco-Fuenmayor (2017) e Jaramillo-Villanueva e Palacios-Orozco (2019) mostram que, no mercado no leite, é comum a existência de um processo de transmissão horizontal no qual os preços do mercado internacional são transmitidos para os mercados domésticos.

Tal relação deriva dos princípios da Lei do Preço Único (LPU), formulada por Mundlak e Larson (1992), segundo a qual em situações iguais de concorrência, dois produtos homogêneos vendidos em países ou regiões diferentes, na ausência de barreiras de comércio e custos de transporte, devem ser ofertados pelo mesmo preço quando expresso na mesma moeda (Krugman; Obstfeld, 2005). A LPU apresenta ainda como as variações dos preços internacionais afetam o comportamento dos preços domésticos. De modo que o preço doméstico de um produto pode ser definido como função de preços domésticos, internacionais e da taxa de câmbio nominal (Krugman; Obstfeld, 2005). Assim, é preciso também considerar a taxa de câmbio praticada entre os países exportadores e importadores.

Os maiores exportadores de leite e derivados para o mercado brasileiro são, respectivamente, Argentina, Uruguai e EUA de acordo com dados do Ministério do Comércio Exterior (2021). No entanto, a cadeia agroindustrial do leite no Brasil tende a ser mais sensível às influências do Mercosul, pelo fato de que cerca de 85% das importações de leite e derivados realizada pelo país, advém da Argentina e do Uruguai (Comexstat; 2021).

Outro fenômeno que afeta os preços do leite, é a transmissão vertical, que ocorre quando uma variação relativa no preço em um determinado nível de mercado influencia a variação no preço em outro nível (Margarido; Shikida; Calvo, 2018). Assim, quando os choques de preços ocorrem em um nível da cadeia em um mercado competitivo, os outros níveis respondem na mesma magnitude, o que reflete a eficiência do mercado (Jaramillo-Villanueva; Palacios-Orozco, 2019; Ben Abdallah; Fekete Farkas; Lakner, 2020).

No caso do mercado brasileiro, os derivados lácteos mais consumidos são os queijos e o leite UHT, sendo o queijo muçarela o mais amplamente consumido na maioria das regiões do país (Ramalho; Siqueira, 2021). Outro derivado capaz de influenciar os preços do leite pago aos produtores é o leite pasteurizado, visto que é utilizado como matéria prima para a produção dos demais itens (Carvalho et al., 2014).

Outro fator apontado pela literatura como capaz de influenciar o volume de produção e o preço do leite, é o preço da carne bovina. Sendo esta uma relação caracterizada por influência mútua. Emrah e Hayran (2021) explicam que a produção de leite e carne bovina são ramos produtivos complementares. Enquanto Michetti et al. (2022) afirmam que existe uma relação intrínseca entre pecuária de corte e de leite. Segundo os autores, a integração

entre estas cadeias ocorre de forma complementar e, em alguns casos, há uma relação de competição (substituição) entre as atividades.

A relação entre os preços da carne bovina e do leite foi analisada por Saghaian, Ozertan e Tekguc (2013), Çelik (2014), Rezitis (2017) e Mudrak et al. (2019). De acordo com Saghaian, Ozertan e Tekguc (2013) contextos de baixos preços do leite, levam à liquidação dos rebanhos leiteiros e queda dos preços da carne bovina num primeiro momento devido ao aumento da oferta de carne. No entanto, com o passar dos meses, o impacto da redução do rebanho gerada pelo abate em larga escala tende a provocar em efeito de elevação, tanto dos preços da carne quanto do leite. Segundo os autores, esses impactos podem ser observados até dois anos após o abate. A mesma relação foi identificada nos estudos de Çelik (2014), Rezitiz (2017) e Mudrak et al. (2019).

O preço da energia elétrica também é identificado como uma variável capaz de afetar o comportamento dos preços do leite pago aos produtores. Conforme explicam Costa e Andrade Júnior (2021), o desenvolvimento e modernização tecnológica ocorrida no setor nas últimas décadas, proporcionou um aumento da utilização de energia elétrica. De modo que alterações em seus preços podem afetar a lucratividade do setor, impactando as decisões dos produtores, e modificando o volume de leite ofertado no mercado. Tais modificações tendem a influenciar os preços, uma vez que os preços são balizados pela relação de oferta e demanda. A este respeito Li, Lopez e Wang (2018) analisaram como os preços da energia são transmitidos aos produtos lácteos de 12 cidades dos EUA entre 2001 e 2011. Os resultados indicam a existência de um repasse de energia assimétrico (um aumento é transmitido mais rápido do que uma queda nos preços).

Considerando que o preço é afetado pelo volume produzido, a sazonalidade, que compreende uma característica marcante da produção de leite, também está relacionada ao comportamento dos preços. A sazonalidade é determinada pelas condições climáticas, como resultado da variação pluviosidade/temperatura que afetam a disponibilidade de pastagens e consequentemente os custos da produção. O impacto da sazonalidade nos preços do leite se dá em função das flutuações no volume produzido que ocorrem entre as estações do ano. Assim, em períodos mais chuvosos, a combinação de uma maior produção com menor custo cria condições para reduzir o preço pago ao produtor. Efeito contrário ocorre quando a pastagem se torna escassa devido à falta de chuvas e os produtores precisam suplementar a alimentação dos animais, elevando os custos de produção e reduzindo o volume de leite ofertado ao mercado (Lins; Vilela, 2006).

Nesse sentido, as mudanças climáticas também se tornaram, ao longo das últimas décadas, fatores que exercem influência sobre os preços do leite. Isto se dá pela variação de curto prazo no volume produzido decorrente de oscilações na temperatura e na precipitação que podem restringir a disponibilidade de pastagens para a alimentação do rebanho, bem como, provocar choques aleatórios nos custos de insumos de produção – como energia elétrica e ração, por exemplo (Nicholson; Fiddaman, 2003).

2.2. Previsão de Preços e RNA

O setor agropecuário é particularmente afetado pelo risco. Fatores como a produção incerta decorrente da dependência de condições ambientais e a baixa elasticidade-preço da demanda dos produtos provocam uma grande flutuação de preços nesse setor (Bacchi; Hoffmann, 2020).

Uma das tarefas cruciais para o gerenciamento de riscos é a previsão de preços dos produtos agrícolas, fator importante para todo o processo de tomada de decisão (Rodrigues et al. 2018). Todavia, como explicam Pinheiro e Sena (2017), o fato de as atividades agropecuárias serem caracterizadas por movimentos cíclicos, elevada volatilidade e sofrerem influência de vários fatores do mercado constitui-se num obstáculo para sua previsibilidade.

A previsão de preços das *commodities* desempenha um importante papel tanto no que tange a gestão de riscos por parte dos produtores, quanto em relação à gestão da segurança alimentar, uma vez que permite aos governos e às empresas planejarem a oferta e procura, com o objetivo de prevenir instabilidade no mercado e assegurar a população tenha acesso aos alimentos (Scodro; Corso, 2023).

Uma importante ferramenta para este propósito são as Redes Neurais Artificiais (RNAs). Tratam-se de sistemas de processamento paralelo distribuído, inspirados no funcionamento do cérebro humano, capazes de lidar com problemas não-lineares e complexos, podendo memorizar, analisar e processar um grande número de dados obtidos de um experimento (Sebastian, 2016; Abraham et al., 2019, Bastiani et al., 2018; Haykin, 2001; Pinheiro et al., 2020).

As RNAs se diferenciam dos modelos tradicionais de previsão por serem modelos que envolvem algoritmos de aprendizado. Os algoritmos buscam imitar a estrutura de interconexões do cérebro humano, com o intuito de incorporar o padrão de comportamento de uma série temporal de modo a prever, da maneira mais eficiente possível, valores futuros dessa série (Turban, 1993). Seu uso vem se destacando como uma das principais técnicas

utilizadas para predição e modelagens em ambientes dinâmicos, nos quais as variáveis mudam constantemente (Silva et al., 2018).

A metodologia para a construção de um modelo de RNAs envolve as etapas de definição do problema; aquisição, limpeza e preparação dos dados; modelagem; treino/testes; e validação (Lima; Corso, 2020).

3. ASPECTOS METODOLÓGICOS:

Nesta seção são descritos os procedimentos metodológicos utilizados para a construção do modelo de previsão do comportamento de preços do leite pago ao produtor na mesorregião do Triângulo Mineiro e Alto Paranaíba. Como o objetivo deste trabalho é realizar a previsão do comportamento dos preços futuros do leite, dois horizontes de previsão são adotados, o primeiro com uma defasagem ($t-1$), buscando realizar a previsão de preços para o mês seguinte, e o segundo com três defasagens ($t-3$) para realizar a previsão para os três meses posteriores.

A definição das variáveis se deu levando em consideração os resultados da revisão de literatura. De acordo com a literatura pesquisada foram apontados como fatores capazes de influenciar os preços do leite no mercado local: os preços do leite no mercado internacional, os preços dos derivados do leite, os preços da carne bovina, os preços das *commodities* energéticas (energia elétrica), a sazonalidade da produção (que é influenciada por fatores climáticos - principalmente o volume de chuvas), e variáveis macroeconômicas como a taxa de câmbio e de inflação.

Com relação aos preços internacionais, foram testados como entradas do modelo de previsão, os preços leite na Argentina, Uruguai e Estados Unidos, que são, respectivamente, os maiores exportadores de leite e derivados para o Brasil (Comexstat, 2021). No entanto, ao se aplicar o teste VIF (*Variance Inflation Factor*) foram observados indícios de multicolinearidade entre os preços da Argentina e do Uruguai, assim optou-se por excluir do modelo os preços argentinos.

No caso dos derivados, foram adotados como variáveis de entrada os preços do leite pasteurizado, do leite UHT e do queijo muçarela. Essa definição se deu com base no fato de os queijos e o leite UHT serem, respectivamente o primeiro e o terceiro derivados lácteos mais consumidos no Brasil. Sendo o queijo muçarela o mais amplamente consumido na maioria das regiões do país (Ramalho; Siqueira, 2021). Já o leite pasteurizado foi incluído no modelo pelo fato de ser bastante influente ao longo da cadeia produtiva, visto que é utilizado como matéria prima para a produção dos demais itens (Carvalho et al., 2014). No entanto ao

verificar o VIF individual das variáveis, foram identificados indícios de multicolinearidade entre os preços do leite pasteurizado e do queijo muçarela, assim optou-se por excluir do modelo os preços do queijo muçarela.

Já em relação as *comodities*, foram incluídos no modelo os preços carne bovina e da energia elétrica. Além destas variáveis também serão consideradas na construção do Modelo de Redes Neurais Artificiais, o volume de precipitação mensal na região, o Índice Geral de Preços de Mercado (IGPM) - como um indicador de inflação, e a taxa de câmbio. A definição de cada variável, bem como de sua fonte, é feita na Tabela 1:

TABELA 1: Definição das Variáveis – Modelo RNAs

	Sigla	Fonte:	Unidade:
Variável Dependente:			
Preço líquido médio pago ao produtor pelo leite in natura na região do Triângulo Mineiro e Alto Paranaíba	TMAP	CEPEA/USP	R\$/litro
Variáveis Explicativas:			
Média de preços pagos aos produtores no Uruguai	UR	CLAL.IT	R\$/litro
Média de preços pagos aos produtores nos Estados Unidos	EUA	CLAL.IT	R\$/litro
Preço do leite pasteurizado em Minas Gerais	PAST	CEPEA/USP	R\$/litro
Preço do Leite UHT em Minas Gerais	UHT	CEPEA/USP	R\$/litro
Preço do Queijo Muçarela em Minas Gerais	MUC	CEPEA/USP	R\$/ kg
Indicador do Boi ESALQ/BM&FBOVESPA	BOI	CEPEA/USP	R\$/unidade
Tarifa Energia Rural CEMIG	ENE	ANEEL	R\$/KWh
Precipitação Total medida na estação meteorológica de Uberlândia/MG	CHU	INMET	mm/mês
Taxa de Câmbio Dólar/real	CAD	IPEAdata	US\$/R\$
Taxa de câmbio real bilateral - IPA-DI - Brasil/Uruguai	CUR	IPEAdata	R\$/UYU
Índice Geral de Preços de Mercado	IGPM	IPEAdata	

Fonte: Elaboração própria.

A fim de encontrar um modelo que oferecesse um melhor desempenho preditivo, optou-se por testar também diferentes arranjos de variáveis, incluindo modelos com as variáveis de preços separadas e um modelo sem os preços internacionais. Os modelos testados são apresentados na Tabela 2:

TABELA 2: Definição dos Modelos de Redes Neurais Artificiais (RNAs)

Modelo	Variáveis	Def.	VIF
1	EUA, UR, PAST, UHT, BOI, ENE, CAD, CUR, IGP, CHU	1	8,9
2	EUA, UR, PAST, MUC, BOI, ENE, CAD, CUR, IGP, CHU	3	9,88
3	EUA, PAST, UHT, BOI, ENE, CAD, IGP, CHU	1	5,70
4	EUA, PAST, MUC, BOI, ENE, CAD, IGP, CHU	3	7,34
5	UR, PAST, UHT, BOI, ENE, CUR, IGP, CHU	1	6,65
6	UR, PAST, MUC, BOI, ENE, CUR, IGP, CHU	3	7,83
7	PAST, UHT, BOI, ENE, IGP, CHU	1	4,70
8	PAST, MUC, BOI, ENE, IGP, CHU	3	6,93

Legenda: EUA: Média de preços pagos aos produtores nos Estados Unidos; UR: Média de preços pagos aos produtores no Uruguai; PAST: Preço do leite pasteurizado em Minas Gerais; UHT: Preço do Leite UHT em Minas Gerais; BOI: Indicador do Boi ESALQ/BM&FBOVESPA; ENE: Tarifa Energia Rural CEMIG; CAD: Taxa de Câmbio Dólar/real; CUR: Taxa de câmbio real bilateral - IPA-DI - Brasil/Uruguai; IGP: Índice Geral de Preços de Mercado; CHU: Precipitação Total medida na estação meteorológica de Uberlândia/MG.

FONTE: Elaboração própria com base nos resultados.

Uma vez definidas as variáveis, procede-se para a elaboração do modelo de Redes Neurais Artificiais (RNAs). A definição dos passos utilizados para elaboração do modelo de RNAs se baseará nas recomendações de Hair et al. (2005) que definem cinco aspectos fundamentais para a construção de um modelo de Redes Neurais para previsão, sendo estes: preparação dos dados; definição da estrutura do modelo; estimativa do modelo; avaliação dos resultados do modelo; e validação do modelo.

A preparação dos dados consiste em duas fases: inicialmente os dados passam por uma etapa de pré-processamento, na qual deve ser realizada a normalização dentro de uma escala de valores definida entre 0 e 1. A fórmula utilizada para normalização dos dados é:

$$X_{normalizado} = (X - X_{min}) / (X_{max} - X_{min})$$

Esse processo é fundamental para evitar problemas computacionais (Lapedes; Farber, 1988), para atender às necessidades do algoritmo (Sharda; Patil, 1992) e para facilitar o aprendizado da rede (Srinivasan et al. 1994). Após a normalização os dados são separados em duas categorias: os de treinamento e os de teste. Os primeiros servem para que a rede "aprenda" as regras associadas ao processo, e os dados de teste são utilizados para verificar o desempenho no referente às condições reais de utilização e a capacidade de generalização (Finocchio, 2014).

A segunda etapa metodológica consistiu na definição da estrutura do modelo. A estrutura do modelo segue o padrão adotado em outros modelos de previsão de comportamento de preços. O tipo de rede utilizada será o *Multilayer Perceptron* (MLP) ou Rede de Múltiplas Camadas e o método de aprendizagem é o *feed forward backpropagation*, sendo utilizado como padrão (*target*) o preço do litro de leite pago ao produtor.

Segundo Hair et al. (2005), apesar de haver a possibilidade de utilizar múltiplas camadas intermediárias, há consenso na utilização de apenas uma camada intermediária (ou escondida), uma vez que uma segunda camada pode acarretar, além de um super ajuste dos dados, um aumento do tempo necessário para estimar os resultados. A função de transferência escolhida para a primeira camada à função *pureling*. A função de adaptação utilizada, por padrão do Matlab, é a LEARNGDM, que é uma função de aprendizado gradiente descendente para pesos. E a função de treino de rede TRAINLN, que é responsável por aplicar o treinamento em uma rede neural. A medida de desempenho de rede adotada é a MSE – *Mean Square Error* (Erro Quadrado Médio).

Para estruturar o modelo também deve ser definida a quantidade de neurônios da primeira camada escondida da rede neural. Na segunda camada escondida à quantidade de neurônios é definida pelo próprio software Matlab. O método comumente utilizado para

definição do número de neurônios da rede é o modelo de Kolmogorov, definido pela equação $n = 2 \cdot n_1 + 1$, onde n_1 – representa o número de variáveis de entradas da rede. Assim, o cálculo do número de neurônios da primeira camada escondida da Rede Neural Artificial é apresentado na Tabela 3:

TABELA 3: Número de Neurônios da primeira camada escondida da Rede Neural Artificial

Modelo	1	2	3	4	5	6	7	8
Nº neurônios	19	19	17	17	17	17	13	13

FONTE: Elaboração própria com base nos resultados.

Após essa definição, é realizada a estimação do modelo. Nesta fase, seguindo o algoritmo de treinamento escolhido são ajustados os pesos das conexões buscando o melhor ajuste do modelo sem super treinar a rede à amostra, ou seja, busca-se um modelo generalizável. A etapa seguinte consiste em determinar o nível de previsão obtido nas variáveis de saída, para avaliar os resultados obtidos com a Rede Neural.

Baseado em Ferreira, Borenstein e Fischmann (2012), neste trabalho serão utilizadas como métricas para avaliação dos resultados: o erro quadrático médio (MSE) e o coeficiente de determinação (R^2). Como parâmetros para definir a rede que apresenta melhor capacidade preditiva, Schalkoff (1997) sugere que se procure alcançar os menores valores possíveis de MSE, e valores próximos de 1 para o coeficiente de determinação (R^2) que indicam que a rede apresenta elevada capacidade preditiva.

A última etapa metodológica consiste na validação do modelo, cujo objetivo é garantir que a solução encontrada é a melhor possível e que ela é tão generalizável quanto possível (Ferreira; Borenstein; Firshmann, 2012).

4. RESULTADOS

Visando atender ao objetivo de elaborar e validar um modelo baseado em Redes Neurais Artificiais para prever o comportamento futuro de preços do leite *in natura* pagos aos produtores no Triângulo Mineiro e Alto Paranaíba foram construídos e treinados oito (8) modelos de RNA que se diferenciam pelas variáveis que compõem as entradas do modelo e pelo número de defasagens adotado, como descrito anteriormente. Os resultados da etapa de treinamento são apresentados na Tabela 4:

TABELA 4: Desempenho dos Modelos na Etapa de Treinamento:


Modelo	Neurônios	VIF médio	MSE	R ²
1	19	8,9	0,0032	0,9563
2	19	9,88	0,0157	0,4360
3	17	5,70	0,0010	0,9683
4	17	7,34	0,0036	0,8659
5	17	6,65	0,0019	0,9424
6	17	7,83	0,0020	0,9261
7	13	4,70	0,0021	0,9324
8	13	6,93	0,0035	0,8722

FONTE: Elaboração própria com base nos resultados.

Analisando as métricas de erro apresentadas na Tabela 5 observa-se que o Modelo 3 apresentou o melhor desempenho preditivo, com o menor valor de MSE (0,0010) e o R² mais próximo de 1 (0,968). Esse modelo é composto pelas séries de preços do leite nos Estados Unidos e pelas séries de preços do leite pasteurizado, do leite UHT, da arroba do boi gordo, da energia elétrica, e da taxa de câmbio, da inflação e da precipitação no período aplicados com 1 defasagem.

O passo seguinte consistiu na validação dos modelos, buscado identificar se os resultados da fase de treinamento se confirmariam. Os valores previstos pelos modelos são apresentados nas Figuras 1 e 2:

FIGURA 1: Valores previstos pelos Modelos com 1 defasagem




FONTE: Elaboração própria com base nos resultados.

Na Figura 1 são apresentados os valores previstos pelos modelos com um período de defasagem, sendo estes os modelos 1, 3, 5 e 7, bem como o preço pagos aos produtores no TMAP no período previsto. Analisando estes valores observa-se que os Modelos 1 e 5 foram aqueles que melhor conseguiram prever os movimentos de alta e baixa nos preços do leite no

período previsto. O Modelo 1 era composto pelas séries do preço dos Estados Unidos e do Uruguai, pelos preços do leite pasteurizado e do queijo muçarela, pelos preços da arroba do boi gordo e da energia rural, pelas taxas de câmbio Dólar/Real e Real/Peso Uruguaio, pelo Índice Geral de preços de Mercado (IGPm) e pela precipitação mensal na região. Já o Modelo 5 não incluía os preços do leite nos Estados Unidos, nem a taxa de câmbio Dólar/ Real.

Os valores previstos, no entanto, apresentam uma magnitude menor do que aqueles praticados no período, especialmente após maio de 2020. A esse respeito, cabe destacar que no período de março a agosto de 2020 os preços do leite aumentaram exponencialmente, em decorrência do início da pandemia de Covid-19 que, como explicado por Carvalho (2021), provocou alterações nos hábitos consumo das famílias que passaram a privilegiar gastos com alimentos e produtos de higiene pessoal; substituíram a alimentação fora do lar pela alimentação domiciliar, o que impulsionou a demanda por lácteos utilizados na culinária, entre eles, creme de leite, muçarela, leite condensado, queijos e requeijão. Além disso, uma parcela da população teve ganhos de renda e passaram a gastar mais com alimentos (fruto, muitas vezes, de incentivos governamentais), enquanto outras tiveram crescimento de poupança devido a economias de outros gastos (viagens, combustível etc.) e acabaram privilegiando uma alimentação mais elaborada.

FIGURA 2: Valores previstos pelos Modelos com 3 defasagens



FONTE: Elaboração própria com base nos resultados.

Na Figura 2 são apresentados os valores previstos pelos modelos com três períodos de defasagem, sendo estes os modelos 2, 4, 6 e 8, bem como o preço pagos aos produtores no TMAP no período previsto. Dentre estes, o que apresentou maior capacidade de prever as

tendências de elevação e redução nos preços do leite pagos aos produtores no TMAP foi o Modelo 2, composto pelas séries do preço dos Estados Unidos e do Uruguai, pelos preços do leite pasteurizado e do queijo muçarela, pelos preços da arroba do boi gordo e da energia rural, pelas taxas de câmbio Dólar/Real e Real/Peso Uruguaio, pelo Índice Geral de preços de Mercado (IGPm) e pela precipitação mensal na região.

Da mesma forma que nos Modelos com uma defasagem, os valores previstos pelo Modelo 2 apresentaram uma magnitude menor do que os valores praticados no período. No entanto, quando se comparam os valores previstos pelos modelos com três defasagens, com aquele que continham uma defasagem, observa-se que o desempenho de todos os modelos piorou, o que reflete a dificuldade de fazer previsões de longo prazo para o mercado do leite.

A fim de avaliar com maior acurácia o desempenho dos modelos, foram calculados os erros de previsão, as métricas de desempenho previamente enunciadas – o Erro Médio Quadrado (MSE) e o Coeficiente de Correlação (R^2). Os resultados obtidos são apresentados na Tabela 5:

TABELA 5: Desempenho dos Modelos na Etapa de Validação:

Modelo	MSE	R^2
1	0,1407	-0,0198
2	0,0090*	0,1946
3	0,1581	0,2908
4	0,0191	0,0102
5	0,1096	-0,0681
6	0,0190*	-0,0672
7	0,1204	-0,0763
8	0,8954	0,4759

Fonte: Elaboração própria com base nos resultados.

Os resultados do MSE apontam que, de todos os modelos validados, aquele que apresentou um melhor desempenho preditivo foi o Modelo 2, com um MSE de 0,009, e o segundo melhor desempenho preditivo foi apresentado pelo Modelo 6, com um MSE de 0,019. Já em termos de R^2 , os melhores desempenhos foram apresentados pelo Modelo 8, com um R^2 de 0,4759.

5. CONSIDERAÇÕES FINAIS

Considerando a importância tanto econômica quanto social da pecuária de leite para o Brasil, e mais especificamente para a região do Triângulo Mineiro e Alto Paranaíba, bem como os desafios e riscos aos quais esta atividade está sujeita, este trabalho teve por objetivo desenvolver um modelo para previsão do comportamento dos preços do leite. Para tanto,

foram utilizados modelos de Redes Neurais Artificiais (RNAs), e testados diferentes arranjos de variáveis buscando identificar aquele que apresentasse o melhor desempenho preditivo.

As variáveis incluídas nos modelos diziam respeito aos preços do leite no mercado internacional, aos preços dos principais derivados lácteos, aos preços da carne bovina (boi gordo) e da energia elétrica, à taxa de câmbio, ao índice de inflação e ao volume de precipitação na região. Essas variáveis foram definidas com base no levantamento da literatura sobre o tema.

Dentre os modelos testados, aquele que apresentou o melhor desempenho preditivo foi aquele composto pelas séries do preço dos Estados Unidos e do Uruguai, pelos preços do leite pasteurizado e do queijo muçarela, pelos preços da arroba do boi gordo e da energia rural, pelas taxas de câmbio Dólar/Real e Real/Peso Uruguaio, pelo Índice Geral de preços de Mercado (IGPm) e pela precipitação mensal na região, considerando uma defasagem de três meses. Este modelo apresentou um MSE de 0,009 e um R^2 0,1946.

Comparando estes resultados é possível afirmar o que a inclusão de diferentes variáveis possibilitada pelo modelo Redes Neurais Artificiais, bem como seu mecanismo de aprendizagem permite que este tenha uma melhor capacidade de prever tendências de elevação ou redução nos preços do leite pagos aos produtores do Triângulo Mineiro e Alto Paranaíba.

Com base nesses resultados, considera-se que o objetivo proposto para este trabalho foi atingido, de modo que foi possível elaborar um modelo que apresenta desempenho satisfatório para realizar previsões para o comportamento dos preços do leite no Triângulo Mineiro e Alto Paranaíba.

Referencias

ACOSTA, A.; IHLE, R.; ROBLES, M. Spatial price transmission of soaring milk prices from global to domestic markets. *Agribusiness*, v. 30, n. 1, p. 64-73, 2014. <https://doi.org/10.1002/agr.21358>

BACCHI, Mirian Rumenos Piedade; HOFFMANN, Rodolfo. Previsão de preços de bovino e frango com modelos de séries temporais. *Revista de Economia e Sociologia Rural*, v. 33, n. 4, p. 9-28, 2020.

BÓRAWSKI, P.; PAWLEWICZ, A.; PARZONKO, A.; HARPER, J.; HOLDEN, L. Factors shaping cow's milk production in the EU. *Sustainability*, v. 12, n. 1, p. 420, 2020. <https://doi.org/10.3390/su12010420>

ÇELİK, Ş. The determination of the long term relationship among number of cattle, milk production and milk price: periods of 1980 to 2013-the Turkish case. *Türkiye Tarımsal Araştırmalar Dergisi*, v. 1, n. 2, p. 196-202, 2014.

CONFEDERAÇÃO DA AGRICULTURA E PECUÁRIA DO BRASIL – CNA. Notícias - CNA debate mercado futuro e previsibilidade de preços do leite. 10 de Maio de 2021.

Disponível em: <https://www.cnabrazil.org.br/noticias/cna-debate-mercado-futuro-e-previsibilidade-de-precos-do-leite>. Acesso em: 02 de out. 2020

COSTA, J. S.; ANDRADE JÚNIOR, L. M. L. Análise da Qualidade de Tensão Elétrica em uma Propriedade Leiteira. **Revista de Engenharia e Pesquisa Aplicada**, v. 6, n. 4, p. 1-9, 2021. <https://doi.org/10.25286/rep.v6i4.1285>

COSTA-FONT, M. ; REVOREDO-GIHA, C. An empirical analysis of UK milk contract prices 2004–2016. **Agribusiness**, v. 34, n. 1, p. 112-141, 2018. <https://doi.org/10.1002/agr.21531>

DONG, F.; DU, X.; GOULD, B. W. Milk Price Volatility and its Determinants. **Agricultural and Applied Economics Association**, 2011.

ENGLER, A. P.; NAHUELHUAL, L. M. Impact of the international milk market on the domestic milk price: a cointegration analysis. **Agricultura Técnica**, v. 63, n. 4, p. 416-427, 2003. <https://doi.org/10.4067/S0365-28072003000400010>

FERNANDES, R. A. S., BRAGA, M. J., LIMA, J. E. D. Elasticidade Na Transmissão E Formação Espacial De Preços De Leite Ao Produtor Nos Principais Estados Brasileiros. In 46th Congress, July 20-23, 2008, Rio Branco, Acre, Brasil (No. 108577). Sociedade Brasileira de Economia, Administração e Sociologia Rural (SOBER). 2008.

FERREIRA, L.; MOURA, G.; BORENSTEIN, D.; FISCHMANN, A. Utilização de redes neurais artificiais como estratégia de previsão de preços no contexto de agronegócio. **RAI Revista de Administração e Inovação**, v. 8, n. 4, p. 6-26, 2011.

FINOCCHIO, M. A. F. Noções de Redes Neurais Artificiais. Universidade Tecnológica Federal do Paraná, 2014.

FOOD AND AGRICULTURAL ORGANIZATION OF THE UNITED NATIONS - FAO. Status and prospects for smallholder milk production—A global perspective. T. Hemme & J. Otte (eds). Rome. 2010

HAIR, J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E.; TATHAM, R. L. **Análise multivariada de dados**. Bookman editora, 2005.

HANSEN, B. G.; LI, Y. An analysis of past world market prices of feed and milk and predictions for the future. **Agribusiness**, v. 33, n. 2, p. 175-193, 2017. <https://doi.org/10.1002/agr.21474>

JARAMILLO-VILLANUEVA, J. L.; PALACIOS-OROZCO, A. Vertical and spatial price transmission in the Mexican and international milk market. **Revista mexicana de ciencias pecuarias**, v. 10, n. 3, p. 623-642, 2019. <https://doi.org/10.22319/rmcp.v10i3.4806>

LABRA-HERNANDEZ, J.; CABAS-MONJE, J.; VELASCO-FUENMAYOR, J. Effects of the international milk on the milk price paid to producers in Chile: a cointegration analysis. **Revista Científica**, Facultad de Ciencias Veterinarias, Universidad del Zulia, v. 27, n. 6, p. 385-392, 2017.

LAPEDES, A.; FARBER, R. How neural nets work. In: Evolution, learning and cognition. 1988. p. 331-346. LAJDOVA, Zuzana; BIELIK, Peter. The evidence of asymmetric price adjustments. **Agricultural economics**, v. 61, n. 3, p. 105-115, 2015. https://doi.org/10.1142/9789814434102_0012

LI, X.; LOPEZ, R. A.; WANG, R. Energy price shocks and milk price adjustments. **Applied Economics Letters**, v. 25, n. 4, p. 268-271, 2018. <https://doi.org/10.1080/13504851.2017.1316820>

- LI, X.; LOPEZ, R.; YANG, S. Energy-milk price transmission at the product brand level. **Agricultural Economics**, v. 49, n. 3, p. 289-299, 2018. <https://doi.org/10.1111/agec.12416>
- LIMA, D.; CORSO, L. L. Aplicação de Inteligência Artificial e Modelos Matemáticos para Previsão de Demanda em uma indústria do ramo plástico. *Scientia cum Industria*, Caxias do Sul, v. 8, n. 2, p. 24-29, 2020.
- LINS, P. M. ; VILELA, P. S. Diagnóstico da pecuária leiteira do Estado de Minas Gerais em 2005: relatório de pesquisa. Belo Horizonte: FAEMG, 2006.
- MEDEIROS, A. P.; MORAES, B. M. M.; BENDER FILHO, R. Integração Espacial nos Preços do Leite: Análise dos Principais Estados Produtores Brasileiros. **Ensaio FEE**, v. 38, n. 3, p. 625-652, 2017.
- MUNDLAK, Y.; LARSON, D. F. On the transmission of world agricultural prices. **World Bank Economic Review**, v. 6, n. 3, p. 399-422, 1992. <https://doi.org/10.1093/wber/6.3.399>
- NICHOLSON, C. F.; FIDDAMAN, T. Dairy policy and price volatility. 2003.
- NORTON, R. Agricultural development policy. Concepts and experiences: concepts and experiences. **Food and Agricultural Organization of the United Nations**, 2004.
- RAMALHO, B. C. F.; SIQUEIRA, K. B. Evolução do consumo de lácteos no Brasil, 2021. Disponível em: [chrome-extension://efaidnbmnnnibpcajpcgiclfindmkaj/https://www.alice.cnptia.embrapa.br/bitstream/doc/1134483/1/Evolucao-consumo.pdf](https://www.alice.cnptia.embrapa.br/bitstream/doc/1134483/1/Evolucao-consumo.pdf)
- RAMOS, J. E. S.; COSTA BORBA, M.; MELO, A. P. S.; LIMA, F. F.; MELO, A. Transmissão de preços pagos aos produtores de leite nos estados brasileiros de maior produção com foco no estado bahiano no período de dez anos. **Revista Eletrônica de Ciências Sociais Aplicadas** - ISSN 2176-5766, v. 5, n. 2, p. 3-26, 2018.
- REZITIS, A. N. Empirical analysis of price relations along the Finnish supply chain of selected meat, dairy, and egg products: A dynamic panel data approach. **Agribusiness**, v. 34, n. 3, p. 542-561, 2018. <https://doi.org/10.1002/agr.21536>
- SAGHAIAN, S.; OZERTAN, G.; TEK GUC, H. Beef and milk price links in Turkey. **Economics Bulletin**, v. 33, n. 4, p. 2607-2616, 2013.
- SCHALKOFF, Robert J. **Artificial neural networks**. McGraw-Hill Higher Education, 1997.
- SCODRO, Leonardo; CORSO, Leandro Luís. Previsão de preço de alimentos utilizando o método ARIMA e inteligência artificial. **Revista Produção Online**, v. 23, n. 1, p. 4869-4869, 2023.
- SHARDA, Ramesh; PATIL, Rajendra B. Connectionist approach to time series prediction: an empirical test. **Journal of Intelligent Manufacturing**, v. 3, p. 317-323, 1992.
- SIQUEIRA, K. B.; SILVA, C. A. B.; AGUIAR, D. RD. Viability of introducing milk futures contracts in Brazil: a multiple criteria decision analysis. **Agribusiness: An International Journal**, v. 24, n. 4, p. 491-509, 2008. <https://doi.org/10.1002/agr.20175>
- SRINIVASAN, D.; LIEW, A. C.; CHANG, C. S. A neural network short-term load forecaster. **Electric Power Systems Research**, v. 28, n. 3, p. 227-234, 1994. [https://doi.org/10.1016/0378-7796\(94\)90037-X](https://doi.org/10.1016/0378-7796(94)90037-X)
- ZIMMERMANN, A.; HECKELEI, T. Structural Change of European Dairy Farms - A Cross-regional Analysis, **Journal of Agricultural Economics** v. 63, n. 3, p. 576-603, 2012. <https://doi.org/10.1111/j.1477-9552.2012.00355.x>