

CAPÍTULO 6

Uso de tecnologia portátil com inteligência artificial para análise de qualidade do leite diretamente em campo

Paola O. Selau, Francine B. Facco, Monique de L. Antunes, Nathália M. Veronezi, Andrieli Stefanello, Renan Cecchin, Pamela I. Otto, Julio Viégas

<https://doi.org/10.69570/mp.978-65-84548-39-8.c6>

Resumo

A espectroscopia no infravermelho próximo (NIRS) portátil surge como uma ferramenta inovadora para avaliação da qualidade do leite, permitindo análises rápidas, não destrutivas e aplicáveis diretamente em campo. Essa tecnologia apresenta grande potencial para monitoramento contínuo e suporte à tomada de decisão na produção leiteira. Este estudo teve por objetivo avaliar o desempenho de sensores NIRS portáteis na análise da qualidade do leite em condições de campo. Foram coletadas 219 amostras de leite de sete mesorregiões do Rio Grande do Sul, que, após aumento artificial de dados, totalizaram 647 amostras utilizadas para treinamento, validação e teste de modelos preditivos baseados em redes neurais. Os sensores avaliados foram os equipamentos portáteis A32R024, A32R019 e A32R026. Os resultados indicaram boa capacidade preditiva para gordura e sólidos totais ($R^2= 0,68 - 0,90$; RMSEP= $0,40 - 0,67$), desempenho moderado para proteína, N-ureico e extrato seco desengordurado (ESD) ($R^2= 0,19 - 0,60$; RMSEP= $0,29 - 0,40$) e predição limitada para lactose (R^2 variando de $0,04 - 0,17$; RMSEP= $0,19 - 0,21$). Apesar das limitações da tecnologia portátil, estratégias como aumento do número de amostras, uso de algoritmos mais robustos e avaliação de diferentes dispositivos podem aprimorar a acurácia e a capacidade discriminatória dos modelos. Conclui-se que os sensores NIRS portáteis representam ferramenta promissora para triagem rápida e monitoramento em tempo real da qualidade do leite, embora não substituam métodos laboratoriais de referência para análises de alta precisão.

Palavras-chave: gordura, lactose, monitoramento, NIR, proteína, sólidos totais.

1. Introdução

O monitoramento da qualidade do leite é de grande relevância para a cadeia produtiva, uma vez que a composição e os parâmetros físico-químicos refletem não apenas o valor nutricional do produto, mas também o estado de saúde dos animais, o manejo alimentar e as condições higiênico-sanitárias da ordenha (Hanuš *et al.*, 2018; Walstra *et al.*, 2005). Métodos convencionais de análise são considerados de referência, porém demandam maior tempo, infraestrutura laboratorial e custos elevados, o que pode limitar sua aplicação rotineira em larga escala (Santos *et al.*, 2021). O impacto econômico da qualidade do leite pode ser dimensionado pelo volume produzido e comercializado nacionalmente, que atingiu um recorde histórico de 6,49 bilhões de litros de leite cru, resfriado ou não, industrializados no Brasil, conforme pesquisa realizada no primeiro trimestre do ano pelo IBGE, divulgada em setembro de 2025.

Nesse contexto, a espectroscopia no infravermelho próximo (NIRS) desponta como uma alternativa promissora, pois possibilita análises rápidas, não destrutivas e simultâneas de múltiplos constituintes, sem necessidade de preparo complexo da amostra ou uso de reagentes químicos (Ciurczak *et al.*, 2014). A tecnologia do NIR se baseia na absorção por radiação eletromagnética por ligações moleculares, gerando espectros característicos que refletem a composição química do material analisado. O uso de modelos quimiométricos robustos permite a correlação entre os espectros obtidos e parâmetros de referência, resultando em metodologias preditivas aplicáveis a diferentes matrizes, incluindo o leite cru (Tsenkova *et al.*, 1999; Berzaghi e Riovanto, 2009), favorecendo o monitoramento em tempo real da qualidade do produto e a tomada de decisão na bovinocultura leiteira.

Embora os NIR de bancada apresentem alta precisão e já sejam consolidados para análises de leite em laboratórios, os avanços tecnológicos em microeletrônica e óptica viabilizaram o desenvolvimento de dispositivos portáteis, capazes de levar a técnica diretamente ao campo (Pu *et al.*, 2021; Beć *et al.*, 2022). Esses sensores de NIR menores e mais acessíveis, têm mostrado potencial para a predição de componentes como gordura, proteína, lactose e sólidos totais, ainda que sua performance varie conforme o modelo e/ou

fabricante, o intervalo espectral e a qualidade da calibração utilizada (De la Roza-Delgado *et al.*, 2017; Guerra *et al.*, 2024).

Estudos recentes (Khan *et al.*, 2024) indicam que, apesar das vantagens de agilidade e praticidade, a robustez dos modelos preditivos em NIR portátil pode ser limitada por fatores como variações de temperatura e umidade do ambiente, heterogeneidade da composição do leite, diferenças de matriz e faixa espectral restrita de alguns sensores. Para minimizar esses efeitos, calibrações regionais, modelos de correção de variabilidade e manutenção periódica dos equipamentos são estratégias recomendadas. Assim, a validação desses equipamentos em condições reais de campo é fundamental para confirmar sua aplicabilidade prática na pecuária leiteira.

Com base nas informações reportadas, a aplicação da tecnologia NIRS portátil em análises de qualidade do leite ainda é pouco explorada no Brasil, evidenciando a necessidade de pesquisas que confirmem a eficiência da tecnologia na prática. Portanto, este capítulo objetiva avaliar a qualidade do leite cru em condições de campo, utilizando um sensor de infravermelho próximo portátil.

2. Espectroscopia Do Infravermelho Próximo (Nirs)

O NIRS é uma técnica analítica baseada na interação da radiação eletromagnética com a matéria, amplamente utilizada para análises qualitativas e quantitativas em diversas áreas, incluindo agricultura, indústria alimentícia, farmacêutica e medicina. O NIR está compreendido, especificamente, em uma faixa de comprimento de onda entre 780 e 2.500 nanômetros, situada entre a luz visível e o infravermelho médio no espectro eletromagnético (Vincent *et al.*, 2020).

O princípio fundamental do NIR baseia-se na absorção de radiação por ligações moleculares como C-H, O-H, N-H e S-H, presentes em compostos orgânicos. Quando a luz incide sobre uma amostra, essas ligações vibram em modos específicos, resultando em espectros característicos que podem ser correlacionados com propriedades físico-químicas da amostra (Osborne *et al.*, 1993).

Além disso, a eficácia do NIRS está intimamente ligada ao uso de métodos quimiométricos, que permitem a construção de modelos preditivos robustos a partir dos espectros obtidos. Tais modelos são desenvolvidos com base em calibrações estatísticas que correlacionam os dados espectrais com análises de referência, possibilitando a estimativa simultânea de múltiplos constituintes com agilidade, precisão e sem a necessidade de reagentes químicos. A combinação entre a rapidez da aquisição espectral, a não destrutividade das amostras e a capacidade de análise de multicomponentes torna o NIRS uma ferramenta altamente atrativa para aplicações em rotinas laboratoriais e monitoramento em tempo real de processos produtivos (Ciurczak *et al.*, 2014).

2.1. Avanços tecnológicos em NIR portátil

O NIR consolidou-se ao longo das últimas décadas como uma ferramenta analítica poderosa e versátil na ciência animal e na indústria de laticínios, inicialmente com o uso de equipamentos de bancada (Berzaghi e Riovanto, 2009). Estudos pioneiros demonstraram a capacidade do NIR de bancada para quantificar não apenas os macrocomponentes do leite, como gordura, proteína e lactose, mas também indicadores de qualidade e saúde do rebanho, incluindo a contagem de células somáticas (CCS) (Tsenkova *et al.*, 1999).

Revisões subsequentes destacaram o potencial do NIR, juntamente com outras tecnologias de sensores, para o monitoramento da qualidade do leite, embora desafios relacionados à robustez, calibração e custo sejam reconhecidos (Brandt *et al.*, 2010). Avanços significativos em miniaturização de componentes ópticos e eletrônicos impulsionaram o desenvolvimento de espectrômetros NIRS portáteis, prometendo levar as vantagens da análise NIRS – rapidez, não destrutividade e ausência de reagentes químicos – diretamente para o campo (Berzaghi e Riovanto, 2009; Pu *et al.*, 2021). Os espectrômetros NIRS portáteis e de bancada diferem principalmente em termos de tamanho, robustez, capacidade analítica e aplicação no campo.

Enquanto os dispositivos de bancada são geralmente maiores, com maior capacidade de processamento e armazenamento de dados, os modelos

portáteis são mais compactos, leves e otimizados para uso direto em campo, facilitando medições rápidas e operadas com uma mão (Cen e He, 2007). Os portáteis costumam ter menor faixa espectral e resolução em comparação com os dispositivos de bancada, ainda assim fornecem resultados confiáveis para aplicações específicas, como a análise de alimentos, forragens e produtos agrícolas (Beć *et al.*, 2022).

Uma das aplicações primárias do NIRS portátil na qualidade do leite é a análise de composição. Diversos estudos avaliaram o desempenho de dispositivos portáteis, incluindo tecnologias como SCiO, NeoSpectra, MEMS FPI, MicroPhazir, na predição de gordura, proteína, lactose e sólidos não gordurosos (SNG) em leite cru. Os resultados indicam que muitos dispositivos portáteis podem fornecer predições adequadas para gordura e, em alguns casos, para proteína e SNG, com desempenho próximo aos padrões de referência, adequado para triagem ou monitoramento (De la Roza-Delgado *et al.*, 2017; Wang *et al.*, 2023; Guerra *et al.*, 2024). No entanto, a precisão pode variar significativamente dependendo do parâmetro, do tipo de sensor e do intervalo espectral utilizado.

A predição de lactose, por exemplo, mostrou-se desafiadora para alguns microsensores (Khan *et al.*, 2024), enquanto outros dispositivos de bolso (pocket-sized) apresentaram desempenho inadequado para lactose, CCS e ureia (Guerra *et al.*, 2024). Analitos como lactose e ureia apresentam bandas de absorção relativamente fracas ou sobrepostas no espectro NIR, dificultando sua identificação precisa, especialmente em dispositivos com baixa resolução espectral e relação sinal-ruído reduzida (Khan *et al.*, 2024).

Muitos desses sensores compactos operam em faixas espectrais restritas, como 740–1070 nm, o que limita a captação de regiões críticas associadas a certos compostos, como as bandas próximas a 1460 nm e 1900–2100 nm (Guerra *et al.*, 2024). No caso da CCS, a predição é ainda mais complexa, pois envolve características físicas e celulares que requerem calibrações indiretas, fortemente dependentes da qualidade do banco de dados e da robustez estatística dos modelos utilizados.

Além da composição básica, o NIR portátil tem sido explorado para detecção de adulterações do leite. Embora estudos mais antigos sobre detecção

de adulterantes específicos (como melamina) tenham utilizado NIR de bancada (Haughey *et al.*, 2015; Su *et al.*, 2018), a capacidade dos dispositivos portáteis para detectar desvios espectrais indica que também pode ser aplicado na detecção de não conformidades ou adulterações grosseiras em campo.

A implementação bem-sucedida do NIRS portátil em campo depende crucialmente de estratégias de calibração robustas e da capacidade de transferência de calibração entre diferentes unidades do mesmo modelo de instrumento (De la Roza-Delgado *et al.*, 2017). A variabilidade inerente aos espectros de produtos lácteos, influenciada por fatores como dia de análise, origem e processamento, precisa ser adequadamente modelada (Harnly *et al.*, 2014). Além disso, o preparo da amostra, embora simplificado em comparação com métodos úmidos, continua sendo um ponto crítico para garantir a representatividade e a precisão das medições em campo (Retsch, 2011).

Apesar dos avanços promissores, os desafios persistem. A precisão dos dispositivos portáteis, especialmente os de baixo custo ou baseados em novas tecnologias de micro sensores, ainda pode ser inferior à dos equipamentos de bancada ou métodos de referência para certos parâmetros (Guerra *et al.*, 2024; Khan *et al.*, 2024). A robustez dos modelos de calibração frente às variações ambientais (temperatura, umidade) e da matriz do leite (raça, dieta, estágio de lactação) em condições de campo requer validação contínua, e a padronização entre diferentes instrumentos e a transferência eficaz de calibrações são essenciais para a adoção em larga escala (De la Roza-Delgado *et al.*, 2017; Pu *et al.*, 2021).

2.2. Validação e desempenho do NIR portátil

A validação de dispositivos portáteis com a técnica NIRS para análise da qualidade do leite é etapa fundamental para assegurar sua aplicabilidade prática, especialmente em condições de campo. O desempenho analítico do NIRS portátil deve ser avaliado com base em critérios estatísticos robustos, como coeficiente de determinação (R^2), erro padrão de calibração (SEC), erro padrão de validação cruzada (SECV) e o coeficiente de correlação entre os valores preditos e os valores reais (r).

Estudos recentes têm demonstrado que para componentes como gordura, proteína e lactose, os equipamentos portáteis apresentam R^2 superiores a 0,90, indicando alto potencial preditivo em situações operacionais (Riu *et al.*, 2020; Guerra *et al.*, 2024; Pu *et al.*, 2021). A capacidade de predição, no entanto, depende da construção de modelos de calibração específicos para a matriz do leite, levando em consideração fatores como variações entre raças, estágio de lactação, manejo alimentar e sazonalidade. Para tal, modelos desenvolvidos a partir de amostras representativas e com ampla variabilidade composicional são mais robustos e transferíveis entre rebanhos (Rego *et al.*, 2020).

2.3. Aplicações do NIR portátil na qualidade do leite

Desde a década de 1960, estudos têm sido realizados utilizando espectroscopia de infravermelho aplicada à indústria alimentícia (Luiz *et al.* 2018). Contudo, nos últimos anos, o NIR portátil tem se destacado como uma ferramenta promissora para a avaliação da qualidade do leite diretamente no campo. Sua aplicação permite análises rápidas e não destrutivas de componentes nutricionais, como gordura, proteína e sólidos totais, facilitando o monitoramento em tempo real da produção leiteira.

Estudos recentes demonstram a eficácia de dispositivos NIR portáteis na predição de características do leite, uma pesquisa realizada por Guerra *et al.*, (2024) avaliou a viabilidade de espectrofotômetros NIRS de bolso para prever a qualidade do leite, utilizando 331 amostras individuais de leite de diferentes raças e rebanhos. Os resultados revelaram que o modelo de predição de teor de gordura foi adequado para controle de qualidade, com um R^2 de 0,93 e um RPD de 3,73. Modelos de predição para proteína, caseína e a razão gordura/proteína também apresentaram desempenho satisfatório, com R^2 superiores a 0,70 e RPD superiores a 1,73, sendo úteis para triagens preliminares. No entanto, a predição de outros componentes, como lactose, contagem de CCS, ureia e ponto de congelamento, apresentou desempenho inferior, indicando limitações na faixa espectral utilizada.

Além disso, a aplicação de sensores NIR portáteis permite a análise instantânea da composição do leite em amostras individuais, eliminando a

necessidade de envio ao laboratório e reduzindo significativamente o tempo de obtenção de resultados. Essa abordagem possibilita a identificação de variações na qualidade do leite de vacas individuais, permitindo ajustes nutricionais específicos para corrigir deficiências na composição do leite, no entanto, suas principais desvantagens são a presença da enorme banda de absorção de água, uma vez que o leite consiste em cerca de 87% de água.

3. Material e Métodos

Foram coletadas 219 amostras de leite em sete mesorregiões do Rio Grande do Sul: 1) Região Centro- Ocidental (Santa Maria, Santiago, São Gabriel, Caçapava do Sul, Alegrete, Rosário do Sul, Itaqui, São Vicente do Sul); 2) Região Centro-Oriental (Cachoeira do Sul, Santa Cruz do Sul, Lajeado, Estrela, Encantado); 3) Região Metropolitana (Porto Alegre, Canoas, Novo Hamburgo, Gravataí); 4) Região Noroeste (Passo Fundo, Erechim, Ijuí, Cruz Alta, Palmeira das Missões); 5) Região Nordeste (Caxias do Sul, Bento Gonçalves, Garibaldi, Flores da Cunha, Farroupilha); 6) Região Sudeste (Pelotas, Rio Grande, Bagé, Santana do Livramento) e 7) Região Sudoeste (Uruguaiana, Quaraí, Alegrete, Itaqui, São Borja).

As amostras de leite foram coletadas com coletores individuais de cada animal, em condições de campo. Na etapa de coleta do leite, foram coletados dois frascos da mesma amostra: um frasco (50 ml) de amostra foi utilizado para analisar em 3 sensores portáteis (NIRS) e o outro frasco (50 ml) foi destinado ao Laboratório de prestação de serviços analíticos da Univates (Universidade do Vale do Taquari), localizado em Lajeado, Rio Grande do Sul, para a obtenção dos valores de referência pelo método citometria de fluxo (ISO 13366-2 | IDF148-2:2006, CCS). Além das amostras do treinamento, algoritmos de aumento de dados foram aplicados para aumentar artificialmente o tamanho do conjunto de dados, resultando em 647 amostras. Destas, 65 amostras foram destinadas à validação e outras 65 ao teste.

O modelo foi treinado utilizando rede neural, com a arquitetura baseada em uma adaptação do SpectraNet. A avaliação do modelo foi realizada através do conjunto de testes em três equipamentos (A32R024, A32R019 e A32R026),

considerando métricas como coeficiente de determinação (R^2), raiz do erro quadrático médio (RMSE), média do erro absoluto (MAE), erros máximos e mínimos.

4. Resultados e Discussão

Os resultados obtidos pelos três sensores portáteis mostraram diferenças consideráveis na capacidade preditiva do modelo de rede neural. Para determinação dos teores de gordura (Tabela 1) os R^2 tiveram boa capacidade preditiva: no equipamento A32R024, $R^2 = 0,71$; no A32R019, $R^2 = 0,90$; e no A32R026, $R^2 = 0,68$; indicando boa capacidade preditiva. O RMSEP* foi de 0,62, 0,40 e 0,62, respectivamente, enquanto o MAE variou de 0,28 a 0,47. Quanto aos erros extremos, o erro máximo variou de 0,78 a 1,36, e o erro mínimo entre -1,17 a -0,98.

Tabela 1. Resultados da predição de gordura no leite por espectroscopia NIR portátil

Equipamentos					
A32R024		A32R019		A32R026	
R^2	0,71	R^2	0,90	R^2	0,68
RMSEP*	0,62	RMSEP*	0,40	RMSEP*	0,62
MAE	0,47	MAE	0,29	MAE	0,43
Assertividade*	82,66	Assertividade*	89,74	Assertividade*	82,95
Erro Máximo	1,36	Erro Máximo	0,78	Erro Máximo	1,59
Erro Mínimo	-0,99	Erro Mínimo	-1,17	Erro Mínimo	-0,98

Legenda: R^2 – Coeficiente de determinação; RMSEP* – Raiz do erro quadrático médio de predição; Média erro absoluto (MAE); Assertividade* – Percentual de acertos dentro do intervalo de confiança definido; Erro Máximo – Maior valor de erro observado; Erro Mínimo – Menor valor de erro observado; Erro Absoluto – Diferença absoluta entre o valor observado e o predito.

Esses valores sugerem boa precisão do modelo para a predição de gordura, com menor dispersão dos erros. Guerra *et al.* (2024) reportaram que um espectrômetro SW-NIR pocket-sized previu teor de gordura com elevada capacidade preditiva ($R^2 = 0,93$; RMSEP* = 0,40), mas reconheceram limitações na predição de outros traços (proteína, lactose, ureia) na mesma faixa espectral, corroborando a heterogeneidade entre os sensores em nosso estudo. Além

disso, abordagens em linha combinadas com *machine learning* mostraram que redes neurais podem melhorar predições de indicadores metabólicos extraídos do leite quando comparadas a PLS tradicionais, ressaltando que o desempenho é fortemente dependente do equipamento, do pré-processamento espectral e da representatividade amostral (Giannuzzi *et al.*, 2022).

A determinação dos teores de proteína (Tabela 2) foi inferior ao observado para gordura, com desempenho moderado e $R^2= 0,36$ (A32R024), $R^2= 0,26$ (A32R019) e $R^2= 0,38$ (A32R026), refletindo uma menor robustez preditiva para esse conjunto de amostras. Os RMSEP* variaram entre 0,34, 0,29 e 0,33, enquanto o MAE oscilou entre 0,21 e 0,27, indicando que, apesar da correlação limitada, os erros absolutos mantiveram-se relativamente baixos. Quanto aos erros extremos, o erro máximo variou de 0,35 a 0,71, e o erro mínimo de -0,91 a -0,70.

Tabela 2. Resultados da predição de proteína no leite por espectroscopia NIR portátil

Equipamentos					
A32R024		A32R019		A32R026	
R ²	0,36	R ²	0,26	R ²	0,38
RMSEP*	0,34	RMSEP*	0,29	RMSEP*	0,33
MAE	0,27	MAE	0,21	MAE	0,27
Assertividade*	92,25	Assertividade*	93,82	Assertividade*	92,30
Erro Máximo	0,51	Erro Máximo	0,35	Erro Máximo	0,71
Erro Mínimo	-0,87	Erro Mínimo	-0,91	Erro Mínimo	-0,70

Legenda: R² – Coeficiente de determinação; RMSEP* – Raiz do erro quadrático médio de predição; Média erro absoluto (MAE); Assertividade* – Percentual de acertos dentro do intervalo de confiança definido; Erro Máximo – Maior valor de erro observado; Erro Mínimo – Menor valor de erro observado; Erro Absoluto – Diferença absoluta entre o valor observado e o predito.

Hussain *et al.* (2024) investigaram o potencial de sensores micro NIR baseados em interferômetro Fabry–Pérot (FPI) para quantificar componentes macroscópicos no leite cru, como gordura, proteína, lactose e sólidos totais. Utilizando dois sensores (S-2.0 e S-2.5), os resultados mostraram que o sensor S-2.0 apresentou RMSEP de 0,15% (gordura), 0,15% (proteína) e 0,30% (sólidos totais). Por outro lado, o sensor S-2.5 apresentou RMSEP de 0,35%

(gordura) e 0,33% (proteína), possivelmente devido à menor penetração da região NIR detectada por esse sensor, resultados semelhantes aos observados em nosso estudo.

Para os teores de lactose (Tabela 3), os modelos apresentaram uma predição limitada em relação à gordura e a proteína, com $R^2 = 0,04$ (A32R024), $R^2 = 0,04$ (A32R019), e $R^2 = 0,17$ (A32R026). O RMSEP* foi de 0,19, 0,20 e 0,21 respectivamente, enquanto o MAE variou entre 0,14 e 0,18, demonstrando desempenho consistente e boa precisão para essa variável. Os erros máximos variaram entre 0,35 e 0,62, e os erros mínimos entre -0,40 e -0,35. Segundo Shicheng *et al.* (2021), que avaliou a precisão de espectrômetros NIR MEMS portáteis para análise de componentes do leite cru, os R^2 para lactose foram relativamente baixos, variando de 0,16 a 0,20 e RMSEP próximos de 0,10 a 0,15%. Essa baixa correlação pode ser atribuída à reduzida variação natural de lactose nas amostras, interferências de outros componentes do leite e a limitações espectrais dos dispositivos portáteis.

Tabela 3. Resultados da predição de lactose no leite por espectroscopia NIR portátil

Equipamentos					
A32R024		A32R019		A32R026	
R ²	0,04	R ²	0,04	R ²	0,17
RMSEP*	0,19	RMSEP*	0,20	RMSEP*	0,21
MAE	0,14	MAE	0,15	MAE	0,18
Assertividade*	96,88	Assertividade*	96,69	Assertividade*	96,14
Erro Máximo	0,40	Erro Máximo	0,62	Erro Máximo	0,35
Erro Mínimo	-0,40	Erro Mínimo	-0,36	Erro Mínimo	-0,35

Legenda: R² – Coeficiente de determinação; RMSEP* – Raiz do erro quadrático médio de predição; Média erro absoluto (MAE); Assertividade* – Percentual de acertos dentro do intervalo de confiança definido; Erro Máximo – Maior valor de erro observado; Erro Mínimo – Menor valor de erro observado; Erro Absoluto – Diferença absoluta entre o valor observado e o predito.

Os resultados para sólidos totais (Tabela 4) apresentaram um bom desempenho, com $R^2 = 0,76$ (A32R024), $R^2 = 0,87$ (A32R019) e $R^2 = 0,74$ (A32R026), com RMSEP* de 0,62, 0,52 e 0,67, respectivamente. O MAE oscilou entre 0,40 e 0,53, indicando um bom desempenho, mas com capacidade limitada para capturar variações mais amplas da composição. Quanto aos erros

extremos, os erros máximos variaram de 1,32 a 1,70 e os erros mínimos de -1,11 a -0,86. Khan *et al.* (2024) também avaliaram sensores NIR para quantificar gordura, proteína e sólidos totais em leite cru, observando RMSEP de 0,30% para os sólidos não gordurosos (SNG), indicando desempenho moderado na predição dessa variável.

Tabela 4. Resultados da predição de sólidos totais no leite por espectroscopia NIR portátil

Equipamentos					
A32R024		A32R019		A32R026	
R ²	0,76	R ²	0,87	R ²	0,74
RMSEP*	0,62	RMSEP*	0,52	RMSEP*	0,67
MAE	0,50	MAE	0,40	MAE	0,53
Assertividade*	95,84	Assertividade*	96,52	Assertividade*	95,45
Erro Máximo	1,53	Erro Máximo	1,32	Erro Máximo	1,70
Erro Mínimo	-0,86	Erro Mínimo	-1,11	Erro Mínimo	-0,91

Legenda: R² – Coeficiente de determinação; RMSEP* – Raiz do erro quadrático médio de predição; Média erro absoluto (MAE); Assertividade* – Percentual de acertos dentro do intervalo de confiança definido; Erro Máximo – Maior valor de erro observado; Erro Mínimo – Menor valor de erro observado; Erro Absoluto – Diferença absoluta entre o valor observado e o predito.

A capacidade preditiva para N-ureico (Tabela 5) apresentou um desempenho moderado, com R²= 0,19 (A32R024), R²= 0,50 (A32R019) e R²= 0,60 (A32R026). O RMSEP* variou entre 4,33, 4,61 e 2,74, respectivamente, enquanto o MAE entre 2,22 e 3,37, refletindo elevada variabilidade e limitações na predição de N-ureico. Os erros máximos variaram de 4,15 e 12,16 e o erro mínimo entre -10,35 e -5,95. Um estudo de Purnomoadi *et al.* (1999) investigou o uso da espectroscopia NIR para medir componentes nitrogenados do leite, os resultados indicaram que a previsão do N-ureico apresentou um R²= 0,31, sugerindo uma precisão limitada na quantificação dessa variável. Corroborando com os resultados Guerra *et al.* (2023) que também utilizaram um espectrofotômetro NIR portátil de ondas curtas para prever o conteúdo de N-ureico encontraram um R²= 0,43. A baixa precisão pode ser atribuída à falta de bandas espectrais específicas para o N-ureico, interferências de outros componentes do leite e limitações dos dispositivos NIR portáteis.

Tabela 5. Resultados da predição de N-ureico no leite por espectroscopia NIR portátil

Equipamentos					
A32R024		A32R019		A32R026	
R ²	0,19	R ²	0,50	R ²	0,60
RMSEP*	4,33	RMSEP*	4,61	RMSEP*	2,74
MAE	3,37	MAE	3,23	MAE	2,22
Assertividade*	59,45	Assertividade*	52,32	Assertividade*	82,78
Erro Máximo	9,31	Erro Máximo	12,16	Erro Máximo	4,15
Erro Mínimo	-6,72	Erro Mínimo	-10,35	Erro Mínimo	-5,95

Legenda: R² – Coeficiente de determinação; RMSEP* – Raiz do erro quadrático médio de predição; Média erro absoluto (MAE); Assertividade* – Percentual de acertos dentro do intervalo de confiança definido; Erro Máximo – Maior valor de erro observado; Erro Mínimo – Menor valor de erro observado; Erro Absoluto – Diferença absoluta entre o valor observado e o predito.

Para a variável extrato seco desengordurado (ESD) (Tabela 6), o modelo obteve valores intermediários, com R²= 0,36 (A32E024), R²= 0,25 (A32R019) e R²= 0,42 (A32R026). O RMSEP* variou entre 0,34, 0,32 e 0,40, respectivamente e o MAE entre 0,26 e 0,30, indicando predição razoável, embora limitada em acurácia entre diferentes equipamentos. Quanto aos erros extremos, os erros máximos variaram entre 0,57 e 0,76, e os erros mínimos entre -0,91 e -0,85. PU *et al.* (2021) avaliaram o MicroPhazir™ aplicado a leite cru e relataram que os modelos de calibração para SNG (sólidos não gordurosos) obtiveram R²= 0,61 e RMSEP= 0,22%. Li *et al.* (2011) em um estudo com espectroscopia NIR de onda curta portátil para SNG observaram desempenho mais limitado, com RMSEP= 0,296, destacando as limitações da tecnologia portátil para estimativa do ESD.

Tabela 6. Resultados da predição de ESD no leite por espectroscopia NIR portátil

Equipamentos					
A32R024		A32R019		A32R026	
R ²	0,36	R ²	0,25	R ²	0,42
RMSEP*	0,34	RMSEP*	0,32	RMSEP*	0,40
MAE	0,26	MAE	0,26	MAE	0,30
Assertividade*	97,19	Assertividade*	97,15	Assertividade*	96,84
Erro Máximo	0,76	Erro Máximo	0,57	Erro Máximo	0,60
Erro Mínimo	-0,85	Erro Mínimo	-0,87	Erro Mínimo	-0,91

Legenda: R² – Coeficiente de determinação; RMSEP* – Raiz do erro quadrático médio de predição; Média erro absoluto (MAE); Assertividade* – Percentual de acertos dentro do intervalo de confiança definido; Erro Máximo – Maior valor de erro observado; Erro Mínimo – Menor valor de erro observado; Erro Absoluto – Diferença absoluta entre o valor observado e o predito.

5. Considerações finais

Apesar de o modelo apresentar limitações para algumas variáveis analisadas, evidenciando limitações da tecnologia portátil, especialmente devido à menor sensibilidade espectral e à variabilidade natural desses componentes, algumas estratégias podem contribuir para aprimorar seu desempenho. Entre elas, destacam-se: o aumento do número de amostras, a utilização de algoritmos de predição mais robustos e a avaliação de diferentes equipamentos NIRS portáteis que apresentem maior sensibilidade e capacidade discriminatória.

6. Referências bibliográficas

- BEĆ, Krzysztof B.; GRABSKA, Justyna; HUCK, Christian W. Miniaturized NIR spectroscopy in food analysis and quality control: Promises, challenges, and perspectives. **Foods**, v. 11, n. 10, p. 1465, 2022.
- BERZAGHI, Paolo; RIOVANTO, Roberto. Near infrared spectroscopy in animal science production: principles and applications. **Italian Journal of Animal Science**, v. 8, n. sup3, p. 39-62, 2009.
- CEN, Haiyan; HE, Yong. Theory and application of near infrared reflectance spectroscopy in determination of food quality. **Trends in Food Science & Technology**, v. 18, n. 2, p. 72-83, 2007.
- CIURCZAK, Emil W.; IGNE, Benoit. **Pharmaceutical and medical applications of near-infrared spectroscopy**. CRC Press, 2014.
- DE LA ROZA-DELGADO, Begoña *et al.* Matching portable NIRS instruments for in situ monitoring indicators of milk composition. **Food Control**, v. 76, p. 74-81, 2017.
- DIAZ-OLIVARES, Jose A. *et al.* Near-infrared spatially-resolved spectroscopy for milk quality analysis. **Computers and Electronics in Agriculture**, v. 219, p. 108783, 2024.
- GUERRA, Alberto *et al.* Application of a short-wave pocket-sized near-infrared spectrophotometer to predict milk quality traits. **Journal of dairy science**, v. 107, n. 6, p. 3413-3419, 2024.
- GIANNUZZI, Diana *et al.* In-line near-infrared analysis of milk coupled with machine learning methods for the daily prediction of blood metabolic profile in dairy cattle. **Scientific reports**, v. 12, n. 1, p. 8058, 2022.
- GULLIFA, Giuseppina *et al.* Portable NIR spectroscopy: The route to green analytical chemistry. **Frontiers in Chemistry**, v. 11, p. 1214825, 2023.

- HANUŠ, O. *et al.* Effect of raw cow milk composition on its physicochemical characteristics. **Mljekarstvo**, v. 68, n. 3, p. 211–223, 2018. DOI: <https://doi.org/10.15567/mljekarstvo.2018.0302>.
- HARNLY, James M. *et al.* Characterization of near-infrared spectral variance in the authentication of skim and nonfat dry milk powder collection using ANOVA-PCA, pooled-ANOVA, and partial least-squares regression. **Journal of agricultural and food chemistry**, v. 62, n. 32, p. 8060-8067, 2014.
- HAUGHEY, Simon A. *et al.* The use of handheld near-infrared reflectance spectroscopy (NIRS) for the proximate analysis of poultry feed and to detect melamine adulteration of soya bean meal. **Analytical Methods**, v. 7, n. 1, p. 181-186, 2015.
- KHAN, HM Hussain *et al.* Quantification of macro-components in raw milk using micro NIR sensors. **Journal of Food Composition and Analysis**, v. 133, p. 106423, 2024.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. Pesquisa Trimestral do Leite. Rio de Janeiro: IBGE, 2025. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9209-pesquisa-trimestral-do-leite.html>.
- LI, Xiao-yun *et al.* Determination of fat, protein and DM in raw milk by portable short-wave near infrared spectrometer. **Spectroscopy and Spectral Analysis**, v. 31, n. 3, p. 665-668, 2011.
- LUIZ, Leandro da Conceicao *et al.* Detection of veterinary antimicrobial residues in milk through near-infrared absorption spectroscopy. **Journal of Spectroscopy**, v. 2018, n. 1, p. 5152832, 2018.
- MAPA – MINISTÉRIO DA AGRICULTURA E PECUÁRIA. Mapa do Leite. Brasília: MAPA, 2023.
- MARCONDES, Marcos Inácio *et al.* Impact of farm size on milk quality in the Brazilian dairy industry according to the seasons of the year. **Ciência Rural**, v. 47, n. 11, p. e20161004, 2017.
- OSBORNE, Brian G.; FEARN, Thomas; HINDLE, Peter H. **Practical NIR spectroscopy with applications in food and beverage analysis**. 1993.
- PU, Yuanyuan *et al.* Recent advances in portable and handheld NIR spectrometers and applications in milk, cheese and dairy powders. **Foods**, v. 10, n. 10, p. 2377, 2021.
- REGO, Guillermo *et al.* A portable IoT NIR spectroscopic system to analyze the quality of dairy farm forage. **Computers and electronics in agriculture**, v. 175, p. 105578, 2020.
- RETSCH, R. Sample Preparation for NIR Analysis. Spectroscopy Online, 1 set. 2011.

- RIU, Jordi *et al.* Rapid analysis of milk using low-cost pocket-size NIR spectrometers and multivariate analysis. **Foods**, v. 9, n. 8, p. 1090, 2020.
- SANTOS, M. V.; FONSECA, L. F. L. Qualidade do leite: interpretação de resultados laboratoriais. 3. ed. Pirassununga: Edição dos Autores, Embrapa, 2021.
- SHICHENG, Qiao *et al.* Nondestructive detection of decayed blueberry based on information fusion of hyperspectral imaging (HSI) and low-field nuclear magnetic resonance (LF-NMR). **Computers and Electronics in Agriculture**, v. 184, p. 106100, 2021.
- SU, Wen-Hao; SUN, Da-Wen. Fourier transform infrared and Raman and hyperspectral imaging techniques for quality determinations of powdery foods: A review. **Comprehensive Reviews in Food Science and Food Safety**, v. 17, n. 1, p. 104-122, 2018.
- DOS SANTOS, Claudia A. Teixeira *et al.* A review on the applications of portable near-infrared spectrometers in the agro-food industry. **Applied spectroscopy**, v. 67, n. 11, p. 1215-1233, 2013.
- TSENKOVA, R. *et al.* Near-infrared spectroscopy for dairy management: measurement of unhomogenized milk composition. **Journal of dairy science**, v. 82, n. 11, p. 2344-2351, 1999.
- VINCENT, Baeten; DARDENNE, Pierre. Application of NIR in Agriculture. In: **Near-infrared spectroscopy: Theory, spectral analysis, instrumentation, and applications**. Singapore: Springer Singapore, 2020. p. 331-345.
- WALSTRA, P. *et al.* **Dairy Science and Technology**. 2. ed. Boca Raton: CRC Press, 2005.
- WANG, Yanyan *et al.* Portable protein and fat detector in milk based on multi-spectral sensor and machine learning. **Applied Sciences**, v. 13, n. 22, p. 12320, 2023.
- YAKUBU, Haruna Gado *et al.* The recent advances of near-infrared spectroscopy in dairy production—A review. **Critical Reviews in Food Science and Nutrition**, v. 62, n. 3, p. 810-831, 2022.

Autores

Paola O. Selau¹, Francine B. Facco¹, Monique de L. Antunes¹, Nathália M. Veronezi¹, Andrieli Stefanello², Renan Cecchin², Pamela I. Otto¹, Julio Viégas¹

¹ Departamento de Zootecnia, Universidade Federal de Santa Maria, Santa Maria, Brasil, ² Zeit Soluções em Inteligência Artificial Ltda – Santa Maria/RS.