

UFRRJ
INSTITUTO DE ZOOTECNIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA ANIMAL

DISSERTAÇÃO

**Impactos do Grau de Processamento Físico da Amostra na Capacidade
Preditiva de um Espectrômetro Portátil do Infravermelho Próximo na
Estimativa do Valor Nutritivo de Gramíneas *Megathyrsus maximus* (syn.
Panicum maximum)**

Priscila Pereira Carneiro

2025



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE ZOOTECNIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA ANIMAL**

**IMPACTOS DO GRAU DE PROCESSAMENTO FÍSICO DA AMOSTRA
NA CAPACIDADE PREDITIVA DE UM ESPECTRÔMETRO
PORTÁTIL DO INFRAVERMELHO PRÓXIMO NA ESTIMATIVA DO
VALOR NUTRITIVO DE GRAMÍNEAS *Megathyrsus maximus* (syn.
Panicum maximum)**

Priscila Pereira Carneiro

*Sob a Orientação do Professor
João Paulo Pacheco Rodrigues*

*e Co-orientação do Professor
Adenilson José Paiva*

*e Co-orientação do Pesquisador
Mirton José Frota Morenz*

Dissertação submetida como requisito
parcial para obtenção do grau de
Mestre(a), no Curso de Pós-Graduação
em Ciência Animal, Área de
Concentração Zootecnia

Seropédica, RJ

Fevereiro de 2025

Universidade Federal Rural do Rio de Janeiro
Biblioteca Central / Seção de Processamento Técnico

Ficha catalográfica elaborada
com os dados fornecidos pelo(a) autor(a)

C289i Carneiro, Priscila Pereira, 1993-
Impactos do grau de processamento físico da amostra
na capacidade preditiva de um espectrômetro portátil
do infravermelho próximo na estimativa do valor
nutritivo de gramíneas *Megathyrsus maximus* (syn.
Panicum maximum) / Priscila Pereira Carneiro. -
Seropédica, 2025.
54 f.: il.

Orientador: João Paulo Pacheco Rodrigues.
Coorientador: Adenilson José Paiva.
Coorientador: Mirton José Frota Morenz.
Dissertação(Mestrado). -- Universidade Federal
Rural do Rio de Janeiro, Programa de Pós-Graduação em
Ciência Animal, 2025.

1. calibração multivariada. 2. gramíneas tropicais.
3. metano entérico. I. Rodrigues, João Paulo Pacheco,
1988-, orient. II. Paiva, Adenilson José, 1983-,
coorient. III. Morenz, Mirton José Frota, 1971-,
coorient. IV Universidade Federal Rural do Rio de
Janeiro. Programa de Pós-Graduação em Ciência Animal.
V. Título.

**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE ZOOTECNIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA ANIMAL**

PRISCILA PEREIRA CARNEIRO

Dissertação/Tese submetida como requisito parcial para obtenção do grau de **Mestre em Ciência Animal**, no Programa de Pós-Graduação em Ciência Animal, área de Concentração em Zootecnia.

DISSERTAÇÃO (TESE), APROVADA EM 26/02/2025

Documento assinado digitalmente
gov.br JOAO PAULO PACHECO RODRIGUES
Data: 27/02/2025 14:43:38-0300
Verifique em <https://validar.iti.gov.br>

Assinatura

João Paulo Pacheco Rodrigues. Dr. UFRRJ
(Orientador)

Documento assinado digitalmente
gov.br BRUNO GROSSI COSTA HOMEM
Data: 27/02/2025 14:36:21-0300
Verifique em <https://validar.iti.gov.br>

Assinatura

Bruno Grossi Costa Homem. Dr. UFV

Documento assinado digitalmente
gov.br THIERRY RIBEIRO TOMICH
Data: 27/02/2025 15:26:46-0300
Verifique em <https://validar.iti.gov.br>

Assinatura

Thierry Ribeiro Tomich. Dr. Embrapa Gado de Leite

DEDICATÓRIA

Dedico esta dissertação a Deus, pela força e sabedoria concedidas ao longo desta jornada.
À minha mãe, pelo amor incondicional, pelos sacrifícios e por sempre acreditar em mim.
Às minhas irmãs, pelo apoio e companheirismo em todos os momentos.
Aos meus sobrinhos, que me fazem querer ser melhor, sempre.
Ao meu namorado, por estar ao meu lado, compartilhando desafios e conquistas.
A todos vocês, minha eterna gratidão.

AGRADECIMENTOS

A Deus, por ser minha fortaleza nos momentos mais difíceis, por iluminar meus caminhos e renovar minhas forças. Sem Ele, essa caminhada teria sido impossível.

À minha mãe, Nádia, meu maior exemplo de força, resiliência e amor incondicional. Por cada palavra de incentivo, por cada sacrifício silencioso, por vibrar com minhas conquistas e sofrer junto comigo nos desafios. Mãe, tudo que sou e tudo que conquisto tem um pedaço de você.

Às minhas irmãs, Paula e Patricia, que estiveram comigo em cada etapa dessa jornada, me incentivando a seguir em frente, me lembrando do propósito dessa caminhada. Ter vocês ao meu lado me dá forças e me enche de orgulho.

Aos meus sobrinhos, Nicolas e Nicole, que são uma das minhas maiores motivações. Vocês me fazem querer ser melhor todos os dias, para que eu possa oferecer a vocês um futuro mais inspirador e cheio de possibilidades.

Ao meu namorado, Márcio, que, de tantas formas, viveu essa pós-graduação comigo. Que esteve presente em cada desafio, segurou minha mão nos momentos de desespero e celebrou cada pequena vitória ao meu lado. Esse diploma também carrega seu nome, pois sem seu suporte, essa jornada teria sido infinitamente mais difícil.

Aos meus fiéis companheiros de quatro patas: Nala e Simon, que já partiram, mas deixaram amor eterno no meu coração; Maya, Tessala, Pequena e Amarok, que tornam meus dias mais leves e cheios de alegria. Cada conquista minha também é um esforço para dar a vocês o melhor, com direito a ração super premium, petisco e banho e tosa toda semana.

À Ariel, que desde o primeiro dia dessa pós-graduação esteve ao meu lado, compartilhando não só os estudos, mas as lágrimas, os surtos e as risadas. Você fez essa caminhada ser mais leve e prazerosa, e sou imensamente grata por termos trilhado esse caminho juntas.

Ao Hugo, o melhor aluno de iniciação científica que eu poderia ter. A verdade é que metade desse trabalho pertence a você. Sempre prestativo, sempre com um sorriso no rosto, valeu cada esforço para garantir que você estivesse na minha equipe. Você foi essencial nessa jornada.

Às incríveis Crysthal, Stella e Letícia, que foram mais do que IC's, foram verdadeiros anjos enviados. Obrigada por cada ajuda, por cada momento de parceria e dedicação. Você tornaram esse processo mais humano e possível.

Ao Jonathan, que chegou por último, mas que fez uma diferença imensa. Sua energia contagiante e seu compromisso trouxeram um brilho especial para essa fase. Sua amizade e leveza tornaram cada desafio mais suportável.

Aos demais membros da equipe RUMINALAB, que de alguma forma contribuíram para a realização das análises e execução desse trabalho. Sem vocês, nada disso teria sido possível.

Ao meu orientador, João Paulo, pela paciência infinita, pela disposição em ensinar e pela confiança depositada em mim. Esse período foi desafiador, mas me transformou como

profissional e como pessoa. Saio dessa jornada com um sentimento enorme de gratidão por todo aprendizado que você me proporcionou.

Aos meus coorientadores, Adenilson Paiva, que me acompanha desde a graduação e que sempre foi uma referência para mim. Sua dedicação, conhecimento e humanidade fazem de você um dos profissionais mais admiráveis que já conheci. Foi uma honra trilhar esse caminho com sua orientação e Mirton Morenz, que além de um cientista brilhante, tem um humor afiado que torna qualquer conversa mais interessante.

Aos queridos professores João Carlos e Pedro Malafaia, que não só me ofereceram um teto, mas uma amizade incrível e ensinamentos que levarei para toda a vida.

A todos os professores que, de alguma forma, contribuíram para que eu chegasse até aqui. Cada aula, cada conselho, cada incentivo foi essencial nessa trajetória. Nenhum de vocês passou despercebido no meu caminho.

À CAPES e CNPq pelo apoio financeiro para a execução da pesquisa e bolsas.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

À FAPERJ pelo apoio financeiro nos processos 200.124/2023 e 210.137/2023.

Às demais instituições que participaram e contribuíram para o desenvolvimento do estudo. A UFV, UFLA, UFJS e Embrapa Gado de Leite, obrigada por nos receberem tão bem e por todo o suporte oferecido.

E, por fim, aos meus amigos, que vibraram comigo nas conquistas e me sustentaram nos momentos difíceis. Vocês foram minha família ao longo desse percurso, e sem vocês, essa conquista não teria o mesmo significado.

A todos vocês, meu mais sincero e profundo agradecimento.

RESUMO

CARNEIRO, Priscila Pereira. **Impactos do grau de processamento físico da amostra na capacidade preditiva de um espectrômetro portátil do infravermelho próximo na estimativa do valor nutritivo de gramíneas *Megathyrsus maximus* (syn. *Panicum maximum*)**. 2025. 54p Dissertação (Mestrado em Ciência Animal). Instituto de Zootecnia, Programa de Pós-Graduação em Ciência Animal, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2025.

A espectroscopia no infravermelho próximo (NIRS) tem se consolidado como ferramenta promissora para análises em tempo real da composição química de gramíneas, melhorando o manejo nutricional e otimizando o consumo de forragem. Este estudo teve como objetivo avaliar o impacto do grau de processamento físico das amostras na capacidade preditiva de um espectrômetro NIRS portátil (pNIRS) para estimar parâmetros nutricionais e fermentativos de gramíneas do gênero *Megathyrsus maximus*. Foram coletadas 120 amostras ao longo de um ano em quatro locais (Seropédica, RJ; Lavras, MG; São João Del Rei, MG; Viçosa, MG) sob diferentes sistemas de manejo, estações do ano e estágios fenológicos, com alturas variando de 30 a 215 cm, e corte residual de 50% da altura inicial do dossel. As amostras foram seccionadas em partículas de 2 a 3 cm, pesadas, secas e moídas, obtendo-se quatro níveis de processamento: fresca (FR), seca (SC), seca e moída a 2 mm (SM2) e a 1 mm (SM1). Em cada nível de processamento foram realizadas seis varreduras espectrais por amostras, utilizando um dispositivo pNIRS (MyNIR, *Spectral Solution*), cobrindo uma faixa de absorbância de 900 a 1700 nm. Todas as calibrações foram realizadas utilizando métodos de química úmida como referência (matéria seca, MS; matéria orgânica, MO; nitrogênio, N; fibra insolúvel em detergente neutro, FDN; fibra insolúvel em detergente neutro corrigida para cinzas, FDNC; fração indigestível da fibra insolúvel em detergente neutro, FDNI, digestibilidade *in vitro* da matéria seca, DIVMS, digestibilidade *in vitro* da fibra insolúvel em detergente neutro, DIVFDN e rendimento de metano *in vitro*, CH₄). Foram testadas 100 possíveis combinações de pré-processamento e os dados espectrais foram analisados por regressão de mínimos quadrados parciais (PLSR) e validados por validação cruzada *leave-one-out* em ambiente *Python* e o software estatístico *R Studio*. Foram comparados os valores do coeficiente de determinação para calibração (R^2 *train*) e validação (R^2 *test*), a raiz do erro quadrático médio de previsão (RMSEP), o erro médio absoluto (MAE), a inclinação da reta (*Slope*) e o intercepto. As calibrações mostraram desempenho superior em amostras com maior nível de processamento físico. Para MS, os melhores resultados foram obtidos com amostras FR apresentando R^2 *train* e R^2 *test* superiores a 0,75, RMSEP de 2,72, MAE de 0,0187 e um *slope* de 0,93 superando os demais níveis de processamento. Para MO, frações fibrosas e digestibilidade, o tratamento SM1 demonstrou melhores ajustes. Enquanto para N e CH₄ os melhores resultados foram obtidos em amostras SM2. No entanto, todos os parâmetros analisados obtiveram bons resultados preditivos R^2 *train* entre 0,70 e 0,78 para FR, seguindo a ordem N>FDNi>DIVFDN>FDNC>FDN. Para parâmetros como DIVMS e rendimento de CH₄ a capacidade preditiva foi intermediária (0,62 e 0,67, respectivamente), mas ainda promissora para uso em campo. Apesar de amostras moídas apresentarem maior robustez estatística, os modelos obtidos com amostras frescas mostraram-se viáveis para aplicação prática. Conclui-se que o pNIRS apresenta potencial para estimativas nutricionais em forragens tropicais *Megathyrsus maximus*, minimamente processadas, podendo auxiliar no manejo nutricional de ruminantes com maior eficiência e menor custo.

Palavras-chave: calibração multivariada, gramíneas tropicais, metano entérico.

ABSTRACT

CARNEIRO, Priscila Pereira. **Impacts of sample physical processing level on the predictive capacity of a portable near-infrared spectrometer for estimating the nutritive value of *Megathyrsus maximus* (syn. *Panicum maximum*) grasses.** 2025. 54p Dissertation (Master Science in Animal Science) Institute of Animal Science, Animal Science Graduate Program, Federal Rural University of Rio de Janeiro, Seropédica, RJ, 2025.

Near-infrared spectroscopy (NIRS) has established itself as a promising tool for real-time analysis of the chemical composition of grasses, improving nutritional management and optimizing forage intake. This study aimed to evaluate the impact of the degree of physical processing of samples on the predictive ability of a portable NIRS spectrometer (pNIRS) to estimate nutritional and fermentative parameters of grasses from the *Megathyrsus maximus* genus. A total of 120 samples were collected over one year in four locations (Seropédica, RJ; Lavras, MG; São João Del Rei, MG; Viçosa, MG), under different management systems, seasons, and phenological stages, with plant heights ranging from 30 to 215 cm and residual cutting at 50% of the initial canopy height. Samples were chopped into 2 to 3 cm particles, weighed, dried, and ground, resulting in four levels of processing: fresh (FR), dried (SC), dried and ground to 2 mm (SM2), and to 1 mm (SM1). At each processing level, six spectral scans were performed per sample using a pNIRS device (MyNIR, Spectral Solution), covering an absorbance range from 900 to 1700 nm. All calibrations were performed using wet chemistry methods as reference (dry matter, DM; organic matter, OM; nitrogen, N; neutral detergent fiber, NDF; ash-corrected NDF, aNDFom; indigestible NDF fraction, iNDF; in vitro dry matter digestibility, IVDMD; in vitro NDF digestibility, IVNDFD; and in vitro methane yield, CH₄). One hundred preprocessing combinations were tested, and the spectral data were analyzed using partial least squares regression (PLSR) and validated by leave-one-out cross-validation in Python and R Studio environments. Calibration performance was assessed using the coefficient of determination for calibration (R² train) and validation (R² test), root mean square error of prediction (RMSEP), mean absolute error (MAE), slope, and intercept. Calibrations showed better performance in samples with higher levels of physical processing. For DM, the best results were obtained with FR samples, showing R² train and R² test values above 0.75, RMSEP of 2.72, MAE of 0.0187, and a slope of 0.93, outperforming the other processing levels. For OM, fiber fractions, and digestibility, the SM1 treatment showed better fits. Meanwhile, for N and CH₄, the best results were obtained from SM2 samples. However, all analyzed parameters showed good predictive performance in FR samples, with R² train values ranging from 0.70 to 0.78, following the order: N>iNDF>IVNDFD>aNDFom>NDF. For parameters such as IVDMD and CH₄ yield, predictive ability was intermediate (0.62 and 0.67, respectively), but still promising for field use. Although ground samples presented greater statistical robustness, models built with fresh samples proved viable for practical application. It is concluded that pNIRS shows potential for nutritional estimates in minimally processed *Megathyrsus maximus* tropical forages, contributing to more efficient and lower-cost nutritional management of ruminants.

Keywords: multivariate calibration, tropical grasses, enteric methane.

LISTA DE TABELAS

TABELA 1. Descrição e quantitativo das cultivares de *Megathyrsus maximus* coletadas.

TABELA 2. Máximo, mínimo, média, desvio padrão e coeficiente de variação da altura, composição bromatológica via úmida, digestibilidade e rendimento de metano *in vitro* das amostras coletadas (% da matéria seca, salvo indicação).

TABELA 3. Performance dos modelos em função de nível de processamento para cada variável e grau de processamento.

LISTA DE FIGURAS

FIGURA 1. Coleta de espectros nos quatro níveis de processamento: fresca (FR); seca (SC); seca e moída a 2 mm (SM2); seca e moída a 1 mm (SM1).

FIGURA 2. Fluxograma representando as etapas de preparo das amostras, aquisição espectral, pré-processamento e calibração dos modelos para predição da composição química e digestibilidade de forragens utilizando espectroscopia no infravermelho próximo (NIRS). As amostras foram analisadas em quatro níveis de processamento físico: fresca, seca, moída a 2 mm e moída a 1 mm, cada uma com seis amostragens espetrais coletadas. Após o pré-processamento dos dados espetrais, foi realizada a calibração dos modelos utilizando validação cruzada do tipo *leave-one-out*. Os modelos foram avaliados pelos parâmetros: erro quadrático médio da predição (RMSEP), coeficiente de determinação da calibração (R^2 train), coeficiente de determinação da validação (R^2 test), inclinação da reta (Slope), intercepto e erro médio absoluto (MAE). As variáveis de referência incluíram matéria seca (MS), matéria orgânica (MO), nitrogênio total (N), fibra insolúvel em detergente neutro (FDN), fibra insolúvel em detergente neutro corrigida para cinzas (FDNc), Fração indigestível da fibra insolúvel em detergente neutro (FDNi), digestibilidade *in vitro* da matéria seca (DIVMS), digestibilidade *in vitro* da fibra insolúvel em detergente neutro (DIVFDN), rendimento de metano *in vitro* (CH_4).

FIGURA 3. Conjunto de espectros brutos individuais na região NIR (900 a 1700 nm) das amostras para o conjunto de calibração e validação nos quatro níveis de processamento testados (Verde = FR; Seco = SC; M2 = SM2; M1 = SM1).

FIGURA 4. Média dos espectros brutos na região NIR (900 a 1700 nm) das amostras para o conjunto de calibração e validação nos quatro níveis de processamento testados (Verde = FR; Seco = SC; M2 = SM2; M1 = SM1).

FIGURA 5. Gráficos de dispersão entre os valores preditos e observados para matéria seca nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

FIGURA 6. Gráficos de dispersão entre os valores preditos e observados para matéria orgânica nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

FIGURA 7. Gráficos de dispersão entre os valores preditos e observados para nitrogênio nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

FIGURA 8. Gráficos de dispersão entre os valores preditos e observados para fibra insolúvel em detergente neutro nos diferentes níveis de preparo físico das amostras: (A) frescas; (B)

secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

FIGURA 9. Gráficos de dispersão entre os valores preditos e observados para fibra insolúvel em detergente neutro corrigida para cinzas nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

FIGURA 10. Gráficos de dispersão entre os valores preditos e observados para fração indigestível da fibra insolúvel em detergente neutro nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

FIGURA 11. Gráficos de dispersão entre os valores preditos e observados para digestibilidade *in vitro* da matéria seca nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

FIGURA 12. Gráficos de dispersão entre os valores preditos e observados para digestibilidade *in vitro* da fibra insolúvel em detergente neutro nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

FIGURA 13. Gráficos de dispersão entre os valores preditos e observados para fração indigestível da fibra insolúvel em detergente neutro nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

LISTA DE ABREVIASÕES

NIR	Infravermelho próximo;
NIRS	Espectroscopia do infravermelho próximo;
pNIRS	Espectroscopia do infravermelho próximo portátil;
FIT-NIR	Espectroscopia do infravermelho próximo com transformada de Fourier;
MS	Matéria seca;
MO	Matéria orgânica;
MM	Matéria mineral;
N	Nitrogênio;
PB	Proteína bruta;
FDN	Fibra insolúvel em detergente neutro;
FDNc	Fibra insolúvel em detergente neutro corrigida para cinzas;
FDNi	Fibra insolúvel em detergente neutro indigestível;
DIVMS	Digestibilidade <i>in vitro</i> da matéria seca;
DIVFDN	Digestibilidade <i>in vitro</i> da fibra insolúvel em detergente neutro;
CH ₄	Produção de metano;
DAMS	Matéria seca aparentemente digerida;
FR	Amostra fresca;
SC	Amostra seca em estufa de ventilação forçada;
SM2	Amostra seca em estufa de ventilação forçada e moída a 2 mm;
SM1	Amostra seca em estufa de ventilação forçada e moída a 1mm;
RMSE	Raiz do erro quadrático médio;
RMSEP	Raiz do erro quadrático médio de predição;
R ² <i>train</i>	Coeficiente de determinação da calibração;
R ² <i>test</i>	Coeficiente de determinação da validação;
MAE	Erro médio absoluto;
DP	Desvio padrão;
CV	Coeficiente de variação;
LOOCV	Validação cruzada <i>leave-on-out</i> ;
PCA	Análise de componentes principais;
MLR	Regressão linear múltipla;
PCR	Regressão por componentes parciais;
PLSR	Regressão por mínimos quadrados parciais;
RPD	Razão entre desempenho e desvio;
MSI	Imagen multiespectral;

SUMÁRIO

1 INTRODUÇÃO	1
2 REVISÃO DE LITERATURA.....	4
2.1 Uso da Tecnologia NIRS na Nutrição Animal	4
3 MATERIAL E MÉTODOS	10
3.1 Local e Amostragem.....	10
3.2 Amostragem Espectral	11
3.3 Composição Química e Digestibilidade <i>in vitro</i>	12
3.4 Produção de Metano <i>in vitro</i>	13
3.5 Calibração	13
4 RESULTADOS	15
5 DISCUSSÃO	25
6 CONCLUSÃO.....	29
7 CONSIDERAÇÕES GERAIS	30
8 REFERÊNCIAS BIBLIOGRÁFICAS	31

1 INTRODUÇÃO

O Brasil possui cerca de 164 milhões de hectares de pastagens (MapBiomas Brasil, 2024), e aproximadamente 90% da produção pecuária ocorre em sistemas de produção baseado em pastagens (Sérgio De Zen *et al.*, 2018). Além disso, 92% do território brasileiro está acima do Trópico de Capricórnio, sendo predominante o clima tropical (Novais, 2023). Ou seja, pastagens tropicais são bases centrais da produção de bovinos no Brasil. Da área utilizada pelo agronegócio no Brasil, aproximadamente 77% são destinados à produção agropecuária (MapBiomas Brasil, 2024). Logo, o manejo adequado dessas pastagens é fundamental para aumentar a produtividade nacional sem a necessidade de expansão de área. Um manejo eficiente tem por objetivo fornecer aos animais um alimento que maximize seu desempenho, através do fornecimento de dietas em quantidade e qualidade apropriadas. Por isso, conhecer o valor nutritivo de uma forrageira é essencial para a eficiência no manejo nutricional.

O gênero de gramíneas *Megathyrsus maximus* (*syn. Panicum maximum*) representava, em 2005, cerca de 12% da área de pastagens plantadas no país, proporção essa que deve ter aumentado até 2025, e é comumente utilizada em sistemas de produção mais intensivos (Macedo, 2005). Esse gênero foi descrito pela primeira vez no livro "*Icones Plantarum Rariorum*" em 1781, pelo botânico holandês Nikolaus Joseph Freiherr von Jacquin (Von Jacquin, 1781). As gramíneas deste gênero são consideradas as mais produtivas forrageiras tropicais propagadas por sementes, apresentando alta produtividade de folhas e porte variável. É bem aceita pelos animais e possui bom valor nutritivo e digestibilidade (Amorim *et al.*, 2020; Costa *et al.*, 2020; Oliveira *et al.*, 2022). Além disso, apresentam uma notável adaptabilidade a climas tropicais (Costa *et al.*, 2020).

Um manejo nutricional adequado é fundamental para o sucesso de qualquer sistema de produção animal. A base da nutrição é o conhecimento da composição química e da digestibilidade dos ingredientes da dieta, especialmente das forragens, que sustentam os sistemas de produção de ruminantes. No entanto, conhecer a composição e o potencial de utilização de gramíneas tropicais representa um desafio, pois essas forragens apresentam grande variabilidade em função da sazonalidade, do manejo, das condições edafoclimáticas, da fertilização, entre outros fatores (Gomide; Gomide, 1999; Parrini *et al.*, 2017, 2019; Queiroz Filho; Silva; Nascimento, 2000).

A análise tradicional por métodos de química úmida, ainda amplamente utilizada na análise de forragens, demanda infraestrutura laboratorial e tempo, o que dificulta o uso da informação para a tomada de decisão em tempo hábil dentro do conceito de nutrição de precisão (Wittkop; Snowdon; Friedt, 2012). Além disso, o uso de tabelas nutricionais, que se baseiam em valores médios de composição, desconsidera características intrínsecas da forragem em condições reais de campo, bem como as variações ambientais, comprometendo a confiabilidade das dietas formuladas (Boever; Vanacker; Brabander, 2003; Hart *et al.*, 2020). Logo, o monitoramento da qualidade da forragem desempenha um papel fundamental no manejo das pastagens e no planejamento nutricional, contribuindo para o melhor desempenho animal (Dale *et al.*, 2013; Givens *et al.*, 2000).

Nesse cenário, a espectroscopia no infravermelho próximo (NIRS, do inglês *Near Infrared Reflectance Spectroscopy*) surge como uma ferramenta promissora para análise rápida,

não destrutiva e de baixo custo da composição química das forragens (Andreu-Rodríguez *et al.*, 2017). As vantagens da NIRS incluem a praticidade e possibilidade de análise simultânea de múltiplos constituintes em poucos minutos, reduzindo custos operacionais (Ciurczak *et al.*, 2021; Molano *et al.*, 2016). O princípio desta técnica baseia-se na absorção de radiação no infravermelho próximo, decorrente de sobretons e combinações de bandas fundamentais associadas a transições vibracionais e rotacionais de ligações químicas (Reich, 2005), comumente encontradas na matéria orgânica, tornando a tecnologia NIRS eficaz na análise de forragens. A recente evolução dos dispositivos portáteis de NIRS possibilita a aplicação direta em campo, viabilizando a obtenção de informações em tempo real e permitindo ajustes nutricionais imediatos. A possibilidade de estimar o valor nutritivo da forragem em tempo real fornece ao técnico ou produtor informações instantâneas quanto a qualidade da forragem, otimizando seu uso e promovendo maior produtividade animal.

Contudo, a eficácia dessa tecnologia depende de vários fatores, dentre eles o nível de processamento da amostra. A precisão das estimativas por NIRS pode ser comprometida por variáveis como heterogeneidade da amostra, teor de umidade, granulometria e presença de contaminantes (Khalsa *et al.*, 2012; Niu *et al.*, 2016; Alomar; Fuchslocher; de Pablo, 2003). Esses fatores tendem a afetar especialmente as amostras pouco processadas, comuns em aplicações de campo. A falta de homogeneização adequada pode levar a variações significativas na medição dos parâmetros de interesse (Parrini *et al.*, 2019). Esses fatores podem interagir com características intrínsecas de cada equipamento, como tamanhos de detectores, dinâmica de obtenção de replicatas, aparatos de controle de luminosidade etc. Por outro lado, quanto maior o processamento, menor a aplicabilidade prática da tecnologia no dia a dia da fazenda, tornando o equilíbrio entre acurácia e praticidade um ponto chave de discussão.

Apesar das limitações, alguns estudos vêm demonstrando a aplicabilidade da espectroscopia NIR, inclusive para amostras frescas, em forragens de clima temperado, com boa capacidade preditiva para matéria seca (MS), proteína bruta (PB), fibra em detergente neutro (FDN), cinzas e digestibilidade (Parrini *et al.*, 2019; Krizsan *et al.*, 2015; Krizsan; Huhtanen, 2013; Dias; Nunes; Borba, 2023). Há também registros da viabilidade de predição da produção de gases durante a digestão ruminal *in vitro*, o que amplia o alcance da tecnologia não apenas para fins nutricionais, mas também ambientais (Dias; Nunes; Borba, 2023; Rego *et al.*, 2020).

Diante do exposto, é notório o potencial da tecnologia NIRS portátil (pNIRS) como ferramenta de apoio à nutrição de precisão, especialmente quando associada a calibrações desenvolvidas para amostras minimamente processadas. E devido às diversas possíveis fontes de variação, estudos específicos que provem conceitos de aplicação, bem como direcionem o aprimoramento do uso de equipamentos para diferentes finalidades analíticas se fazem necessários. Sendo fundamental validar o uso prático da tecnologia em campo, a fim de desenvolver soluções que atendam à realidade da produção pecuária em regiões tropicais.

Nesse sentido, é necessário investigar se a obtenção de espectros sem ou com o mínimo de processamento é suficiente para gerar modelos preditivos robustos. A hipótese é de que espectros obtidos a partir de amostras minimamente processadas são capazes de estimar a composição química, digestibilidade e rendimento de metano da digestão ruminal *in vitro* de gramíneas *Megathyrsus maximus* (*syn. Panicum maximum*). Sendo assim, objetivou-se avaliar os efeitos que o grau de processamento físico da amostra pode causar na capacidade preditiva de um pNIRS em estimar os teores de matéria seca (MS), matéria orgânica (MO), nitrogênio (N), fibra insolúvel em detergente neutro (FDN), fibra insolúvel em detergente neutro corrigida

para cinzas (FDNc), fibra insolúvel em detergente neutro indigestível (FDNi), digestibilidade *in vitro* da matéria seca (DIVMS) e da FDN (DIVFDN) e o rendimento de metano (CH_4) *in vitro* em gramíneas tropicais do gênero *Megathyrsus maximus* (*syn. Panicum maximum*).

2 REVISÃO DE LITERATURA

2.1 Uso da Tecnologia NIRS na Nutrição Animal

Um dos principais desafios na produção animal é o fornecimento de dietas formuladas conforme as exigências nutricionais específicas de cada fase do ciclo produtivo (Neumann *et al.*, 2018). Tradicionalmente, pequenos e médios produtores elaboram essas dietas de forma empírica, sem considerar a real composição dos alimentos disponíveis na propriedade. Essa prática pode resultar tanto em subnutrição quanto em fornecimento excessivo de nutrientes, comprometendo a produtividade dos animais e gerando prejuízos econômicos.

Durante os períodos de estiagem, a suplementação com alimentos concentrados torna-se a principal estratégia para mitigar os efeitos da escassez e da baixa qualidade da forragem disponível nos pastos. No entanto, a intensificação dos sistemas de produção levou muitos produtores a utilizarem a suplementação ao longo de todo o ano. Essa prática, embora aumente a produtividade, eleva os custos de produção, principalmente em função do alto preço dos concentrados (Silva *et al.*, 2009). Assim, conhecer a composição químico-bromatológica da forragem é fundamental para reduzir os impactos econômicos decorrentes da variação no custo dos suplementos.

A análise da composição bromatológica dos alimentos, tanto da forragem quanto dos concentrados, é essencial para garantir uma formulação nutricional adequada (Beć *et al.*, 2020; Evangelista *et al.*, 2021). No entanto, a metodologia convencional, baseada em química úmida, com uso de amostras secas e moídas, além de demandar longo tempo de processamento, pode induzir alterações químicas não enzimáticas durante o preparo (Borreani *et al.*, 2018). Essa prática ainda enfrenta entraves relacionados ao tempo necessário para coleta, transporte, preparo e análise das amostras, além dos custos envolvidos (Wittkop; Snowdon; Friedt, 2012; Borreani *et al.*, 2018).

Gramíneas forrageiras, especialmente as tropicais, apresentam elevada variabilidade composicional ao longo do ano, devido à susceptibilidade a variações sazonais, edafoclimáticas e ao estádio fenológico (Parrini *et al.*, 2017) alterando sua composição químico-bromatológica e digestibilidade. A dificuldade de conhecer de forma rápida a composição da forragem utilizada no campo constitui uma limitação para o aumento da eficiência produtiva de ruminantes em sistemas a pasto. Nesse cenário, o conhecimento da composição química de amostras *in natura* ganha destaque por eliminar a necessidade de preparo laboratorial e permitir análises diretas no campo (Evangelista *et al.*, 2021). Essa possibilidade viabiliza ajustes imediatos nas dietas, promovendo maior eficiência produtiva.

A NIRS, apresenta-se como uma tecnologia rápida e não destrutiva para análise de forragens (Andreu-Rodríguez *et al.*, 2017), mostrando-se eficiente na predição da composição química e digestibilidade (Liu *et al.*, 2021; Moscoso; Balocchi, 2016). O uso crescente da técnica na avaliação de gramíneas forrageiras está associado a velocidade de análise, custo inferior a métodos oficiais, conveniência de uso e a estimativa simultânea de múltiplos parâmetros (Ciurczak *et al.*, 2021; Molano *et al.*, 2016).

A descoberta da radiação infravermelha remonta a 1800, quando Frederick William Herschel observou que a temperatura continuava aumento além da luz visível, o que hoje é

reconhecido como radiação do infravermelho próximo (Naes *et al.*, 2002; Cienfugos, 2003; Burns; Ciurczak, 2007). No entanto, durante muito tempo, os estudos nessa área foram limitados pela complexidade espectral, já que as bandas de absorção da região NIR (do inglês, *Near Infrared*) são formadas por sobretons e combinações de vibrações fundamentais, dificultando a extração de informações significativas (Pasquini, 2003). Somente a partir da década de 1970, com o avanço da quimiometria e a aplicação de modelos matemáticos robustos, o uso da tecnologia NIRS passou a se expandir rapidamente, tornando-se cada vez mais relevante para aplicações industriais e agropecuárias (Tibola *et al.*, 2018).

A tecnologia se consolidou nas últimas décadas como uma ferramenta capaz de monitorar qualitativamente recursos associados a produção agropecuária. Sendo comum sua utilização para avaliação de propriedades do solo, produtos agropecuários, além de fezes e forragem (Andueza *et al.*, 2017; Nguyen *et al.*, 2011; Su *et al.*, 2014; Zhang *et al.*, 2018). A utilização da tecnologia na avaliação de forragens teve início com o trabalho de Norris e colaboradores (1976), que conseguiram predizer com acurácia a digestibilidade *in vitro* e *in vivo* de forragens. Desde então, tornou-se crescente a adoção da técnica na determinação dos mais diversos parâmetros químicos em forragens conservadas, grãos e forrageiras (Barber *et al.*, 1990; Cozzolino; Moron, 2004; Garnsworthy; Wiseman; Fegeros, 2000; Park *et al.*, 1998).

Dentre suas bases teóricas, destacam-se a Lei de *Lambert-Beer*, que descreve a relação linear entre a absorção da radiação e a concentração da amostra. Segundo esta lei, a absorção da radiação em uma solução é diretamente proporcional à concentração do componente absorvente e à espessura da amostra. No entanto, vale a ressalva de que a intensidade do sinal também é influenciada pela temperatura, pressão e pela presença de outros componentes no material (Jha; Garg, 2010; Norris *et al.*, 1976). Outro conceito importante é o de bandas de absorção, que são responsáveis por fornecer informações sobre as moléculas presentes na amostra. Estas bandas são associadas a vibrações moleculares específicas, como as de estiramento de ligações químicas e deformações de grupos funcionais (Alomar *et al.*, 2009; Tassone; Masoero; Peiretti, 2014). Diversas ligações orgânicas (*e.g.* CH, CC, C=C, CN, OH, NH) possuem bandas de absorção na região NIR (780 nm e 2500 nm) (Corson *et al.*, 1999), permitindo a detecção de lipídeos, proteínas, carboidratos e outros componentes de alta complexidade (Alomar *et al.*, 2009).

A tecnologia se baseia nas interações da radiação eletromagnética com as moléculas para se obter informações quanto as características estruturais e composição química (Burns; Ciurczak, 2007). A partir da análise de espectros de absorância é possível estimar a concentração de componentes específicos, sem a necessidade de destruição da amostra (Ibáñez; Alomar, 2009). A maioria das bandas de absorção no infravermelho próximo resulta da combinação ou repetição de bandas fundamentais do infravermelho, que ocorrem devido as transições vibracionais e rotacionais das moléculas (Reich, 2005). Como essas interações são comuns na matéria orgânica, a espectroscopia NIR apresenta grande potencial para analisar a composição química das forragens.

Atualmente, a análise da composição química de gramíneas forrageiras é realizada em laboratório, por meio de métodos analíticos de química úmida ou utilizando espectrômetros NIR de bancada. No entanto, o tempo gasto com o transporte, preparo e secagem das amostras limita a frequência das análises (Wittkop; Snowdon; Friedt, 2012), o que é problemático diante das rápidas variações na composição de gramíneas forrageiras. O uso da tecnologia NIRS na avaliação rápida de plantas forrageiras tem se mostrado uma ferramenta estratégica para detectar variações sazonais e regionais relevantes à nutrição animal. Essas informações são

fundamentais para o desenvolvimento de dietas e suplementos com composições mais ajustadas à realidade nutricional dos alimentos disponíveis. Com a utilização do NIRS, é possível estimar de forma rápida e precisa a composição química dos alimentos, dispensando o uso de reagentes químicos e equipamentos labororiais especializados. Isso não apenas reduz o custo das análises, como também minimiza a geração de resíduos, tornando o processo mais sustentável (Pujol; Pérez-Vendrell; Torrallardona, 2007).

Além de sua aplicação em análises labororiais convencionais, a espectroscopia no infravermelho próximo está sendo integrada às tecnologias da agricultura de precisão. A modernização dos equipamentos, aliada à portabilidade dos dispositivos, permite realizar análises diretamente no campo, em tempo real, o que torna o monitoramento da qualidade da forragem mais ágil, eficiente e prático (Dias; Nunes; Borba, 2024; Pasquini, 2003). Entre os avanços mais relevantes, destaca-se a possibilidade de realizar análises sem qualquer tipo de processamento prévio da amostra, o que agiliza significativamente o processo analítico.

O pNIRS, apresenta desempenho superior ao de tabelas de consulta e modelos de análise multiespectrais (MSI) para estimativas da qualidade nutricional da forragem. Ainda que apresente alguns desafios relacionados à calibração, os erros observados têm sido baixos e corrigíveis, o que evidencia o potencial da tecnologia para uso prático por agricultores em breve (Hart *et al.*, 2020). Com a evolução da microtecnologia, os dispositivos portáteis tornaram-se menos suscetíveis às variações ambientais, como temperatura, vibração e poeira. Podem ser acoplados a máquinas agrícolas ou utilizados diretamente nas propriedades rurais (Crocombe, 2018; Béc *et al.*, 2020), proporcionando resultados imediatos, de maneira não destrutiva. Essa agilidade permite ajustes rápidos nas dietas, baseados em dados reais, contribuindo para o aprimoramento da nutrição animal (Zhang *et al.*, 2022).

Apesar de, em geral, apresentarem desempenho inferior ao de espectrômetros de bancada, os dispositivos portáteis vêm sendo amplamente testados no setor agropecuário. Como para avaliar, por exemplo, o teor de MS, uma variável crítica na formulação de dietas. A estimativa imprecisa desse parâmetro é uma das principais fontes de erro nutricional, e seu monitoramento com pNIRS tem potencial para resultar em dietas mais equilibradas e melhor desempenho produtivo dos animais (Evangelista *et al.*, 2021). Além disso, estudos apontam que o uso da técnica tem se mostrado eficiente na predição de parâmetros como nitrogênio (N), fibra insolúvel em detergente neutro (FDN) e ácido (FDA), e digestibilidade *in vitro* da matéria seca (DIVMS) em diferentes tipos de forragem (Brogna *et al.*, 2018; Cozzolino *et al.*, 2006; Molano *et al.*, 2016; Vranić *et al.*, 2020).

Embora a análise de forragens frescas *in loco* utilizando o NIRS seja uma técnica promissora, ainda apresenta algumas limitações, como a necessidade de calibração específica para cada gênero de forragem em diferentes condições. Visto que a composição e o tipo de ligações químicas dessas plantas podem variar amplamente em função de fatores como genética, idade, condições edafoclimáticas e fatores ligados a colheita e processamento das amostras (Dias; Nunes; Borba, 2024). A título de exemplo, gramíneas tropicais podem conter nitrogênio em diferentes formas químicas. A braquiária-do-brejo (*Urochloa arrecta* (Hack.) Morrone & Zuloaga), acumula nitrogênio em suas folhas na forma de nitrato (Cazetta; Villela, 2004), enquanto plantas que crescem em ambientes sombreados tendem a apresentar maior concentração de clorofila (Malaviya *et al.*, 2020). Esses exemplos demonstram que, embora o nitrogênio esteja presente, sua disponibilidade ocorre em diferentes tipos de ligações orgânicas, o que influencia a forma como ele encontra-se na amostra. Outro exemplo, é o capim Massai (*Megathyrsus maximus* cv. Massai) que possui maior frequência de estrutura Girder I quando

comparado a outras gramíneas pertencentes ao mesmo gênero, modificando a disposição anatômica e química da fibra, influenciando sua digestibilidade (Urbano *et al.*, 2023). Desse modo, as características intrínsecas às plantas forrageiras e o ambiente em que elas se encontram influenciam suas leituras espectrais. Outro fator a ser destacado, é o controle de interferência na obtenção de espectros em nível de campo, bem como o desenvolvimento de técnicas de amostragem que ponderem para características morfofisiológicas das plantas. Além disso, a precisão varia significativamente, dependendo do tipo de forragem e do parâmetro químico analisado (Cozzolino *et al.*, 2006).

As amostras de forragem apresentam alta complexidade e heterogeneidade em sua composição (Agelet; Hurlburgh, 2010), o que representa um desafio para a avaliação por espectroscopia NIR, especialmente quando se busca realizar a análise com o mínimo de processamento. Fatores como a umidade, a presença de contaminantes, a textura e o tamanho de partícula, podem interferir significativamente na qualidade dos espectros obtidos, reduzindo a precisão das previsões (Dias; Nunes; Borba, 2023). A técnica NIRS apresenta melhor desempenho quando aplicada a amostras uniformes e homogêneas, geralmente obtidas após secagem e moagem fina, que favorecem a reflexão difusa e diminuem o efeito de espalhamentos ópticos (Ikoyi *et al.*, 2020).

A leitura espectral de amostras *in natura* é especialmente desafiadora, pois a variação no tamanho da partícula e a alta umidade influenciam na absorção da radiação e na formação do espectro, interferindo na linha de base e aumentando o ruído instrumental. A água, em particular, é um forte absorvedor de radiação na região do NIR, com alta absorção entre 1400 e 1410 nm, especialmente em alimentos com teor de umidade superior a 70% (Büning-Pfaue, 2003). Além disso, compostos como sacarose, amido e celulose, presentes em forragens, possuem grupos hidroxilas (OH) que absorvem em comprimentos de onda similares aos da água, comprometendo sua identificação (Osborne; Douglas, 1981). Já a granulometria, afeta diretamente o perfil espectral por meio de alterações no espalhamento superficial e na profundidade de penetração da radiação, influenciando a refletância difusa (Ikoyi *et al.*, 2020; Pasquini, 2018).

Entre as principais fontes de variância indesejada em espectros NIR estão os ruídos espectrais, os espalhamentos e os desvios de linha-base (Tibola *et al.*, 2018). Esses efeitos podem ter origem tanto nas características da amostra (como temperatura e granulometria) quanto no próprio equipamento (como distorções espectrais e ruídos nos detectores). Para minimizar essas interferências, a aplicação de pré-tratamentos matemáticos nos dados espectrais tem se mostrado eficaz (Pasquini, 2003; Zhang *et al.*, 2022). Nos últimos anos, avanços em softwares quimiométricos e em técnicas de pré-processamento, como correção de dispersão, têm permitido melhorar a qualidade dos espectros obtidos de amostras frescas, reduzindo os efeitos adversos da umidade e do tamanho de partícula (Ferreira, 2016). Ainda assim, o alto teor de água e a variabilidade intrínseca de alimentos volumosos como silagens e forragens frescas dificultam a construção de modelos robustos de calibração e validação, especialmente quando a variação ambiental é elevada (Zhang *et al.*, 2022).

Como resultado, muitas metodologias descritas na literatura optam pela secagem e moagem das amostras, o que melhora a precisão analítica, mas aumenta o tempo necessário para obtenção dos resultados (Cozzolino *et al.*, 2006; Parrini *et al.*, 2019). Apesar disso, diversas pesquisas confirmam a capacidade do NIRS de fornecer informações confiáveis sobre a qualidade de pastagens e silagens (Parrini *et al.*, 2019; Acosta *et al.*, 2020).

O desenvolvimento de calibrações é uma etapa central, que garante ou não a obtenção de resultados precisos e acurados. Para isso, é necessário o uso de dados de amostras representativas do material a ser analisado, que devem ser sustentados por métodos analíticos de via úmida adequados e em laboratórios idôneos (Andueza *et al.*, 2011). Ou seja, a qualidade e precisão dos resultados dependem diretamente da qualidade das amostras utilizadas e da correta calibração dos instrumentos (Andueza *et al.*, 2011; Garcia; Cozzolino, 2006). Além de calibrações adequadas, a padronização de métodos de obtenção de dados espectrais é central, pois essa etapa caracteriza a interferência de fatores como luz solar ou ambiente, variação da temperatura da amostra e detectores, contaminações inerentes ao manuseio inadequado das amostras, além de outros (Yan; Siesler, 2018).

A construção de modelos analíticos por NIRS envolve uma série de etapas que se iniciam com o pré-processamento dos dados espectrais. Essa fase consiste na aplicação de transformações matemáticas que visam minimizar interferências, como variações no tamanho e densidade das partículas das amostras, garantindo que o sinal espectral reflita de forma mais precisa as características químicas do material analisado (Tibola *et al.*, 2018). Dessa forma, busca-se isolar o sinal verdadeiro da amostra, reduzindo os efeitos de ruídos aleatórios. A etapa seguinte é a calibração, que estabelece a relação entre os sinais espectrais e os valores reais de uma propriedade de interesse. Esse processo consiste em associar medições instrumentais aos valores obtidos por métodos de referência (Cen; He, 2007; Martens; Naes, 1996). A calibração pode ser descrita em duas fases: a descritiva, na qual se constrói um modelo com base em amostras com concentrações conhecidas; e a preditiva, que utiliza esse modelo para estimar valores em novas amostras (Pimentel; Neto, 1996).

A calibração multivariada é uma técnica que visa contornar os ruídos gerados pelas interferências, através da utilização de um conjunto de amostras com valores conhecidos que servem como base para calibrar o equipamento e estimar valores desconhecidos (Pasquini, 2018). A análise multivariada é conduzida em etapas sequenciais para identificar erros e amostras discrepantes, além de maximizar a extração de informações relevantes dos dados (Sena *et al.*, 2017; Varmuza; Filzmoser, 2016). Diversas técnicas de análise multivariada podem ser aplicadas na construção desses modelos, como a análise de componentes principais (PCA; *Principal Component Analysis*), a regressão linear múltipla (MLR; *Multiple Linear Regression*), a regressão de componentes principais (PCR; *Principal Components Regression*) e a regressão por mínimos quadrados parciais (PLS; *Partial Least Squares Regression*). Dentre essas, PCA e PLSR são as mais utilizadas. A PCA é voltada à visualização da estrutura dos dados, identificação de padrões e detecção de *outliers* (Souza; Poppi, 2012), enquanto a PLSR é amplamente empregada na calibração por considerar simultaneamente os espectros e os valores de referência (Shi *et al.*, 2012).

A regressão PLSR é amplamente reconhecida como a abordagem mais comum na construção de modelos de calibração multivariada, apresentando resultados eficazes em diversas aplicações (Shi *et al.*, 2012). O modelo PLSR é fundamentado na combinação simultânea das informações contidas na matriz X (variáveis independentes, geralmente os dados espectrais) e na matriz Y (variáveis dependentes, como a concentração de um determinado constituinte). A partir dessa integração, são geradas variáveis latentes, também chamadas de fatores ou componentes principais, que são utilizadas para construir os modelos (Nunes, 2008).

Após a construção dos modelos de calibração para a propriedade em estudo, é essencial avaliar sua exatidão e reprodutibilidade por meio de um processo denominado validação, etapa

chave da quimiometria. Essa validação pode ser realizada de duas formas principais: externa ou interna (Martens; Naes, 1996). Na validação externa, utiliza-se um conjunto de amostras completamente distinto daquele usado para a calibração. Essas amostras precisam passar novamente por análises laboratoriais com métodos de referência, o que aumenta o tempo e os custos envolvidos (Sotelo, 2006). Já na validação cruzada, modalidade mais comum de validação interna, as próprias amostras da calibração são reutilizadas, retirando-se uma ou mais amostras do conjunto, construindo o modelo com as demais, e prevendo as retiradas. Esse processo é repetido até que todas as amostras tenham sido previstas (Brereton, 2000).

A avaliação da eficiência dos modelos considera sua capacidade de prever corretamente novas amostras, que não foram incluídas no processo de calibração. Para isso, são utilizadas métricas como o erro quadrático médio da predição (RMSEP; *Root Mean Squared Error of Prediction*) e o coeficiente de determinação (R^2) entre os valores estimados e os valores obtidos por métodos analíticos de referência. Modelos preditivos considerados robustos devem apresentar altos valores de R^2 e RMSE de calibração e validação (Williams; Sobering, 1993; Williams, 2001). Na prática, modelos NIRS com R^2 superiores a 0,75 são geralmente considerados adequados para predição (Tran *et al.*, 2010; Ferreira, 2016; Pasquini, 2018).

Em resumo, o desenvolvimento completo de modelos NIRS possui, normalmente, um fluxo de cinco etapas fundamentais: (1) análise da composição química da amostra por métodos laboratoriais padronizados; (2) aquisição dos espectros NIR das mesmas amostras; (3) aplicação de pré-processamentos espectrais para remover ruídos e variações indesejadas associadas à instrumentação, condições ambientais ou manipulação das amostras; (4) construção do modelo de calibração utilizando amostras com valores conhecidos obtidos por técnicas de referência; e (5) validação do modelo, seja com um novo conjunto de amostras independentes, também previamente analisadas por métodos convencionais, ou por validação interna cruzada (Cen; He, 2007).

A caracterização precisa da composição químico-bromatológica de volumosos é uma estratégia fundamental para otimizar o manejo alimentar e reduzir os custos de produção, especialmente frente à alta volatilidade dos preços dos concentrados. O NIR portátil surge como uma ferramenta viável e promissora, permitindo análises rápidas, não destrutivas e *in loco*, favorecendo decisões nutricionais mais acertadas e promovendo maior sustentabilidade econômica e ambiental na produção animal. Diante da necessidade de avaliar forrageiras de forma rápida e eficiente, e considerando o potencial da tecnologia NIRS como solução viável, torna-se essencial investigar, com parcimônia, os procedimentos de aplicação dessa tecnologia, especialmente quando se utilizam dispositivos portáteis, a fim de garantir a qualidade e a confiabilidade dos resultados obtidos.

3 MATERIAL E MÉTODOS

Todos os procedimentos envolvendo animais foram aprovados pelo Comissão de Ética de Uso de Animais em Pesquisa do Instituto de Zootecnia da Universidade Federal Rural do Rio de Janeiro, sob protocolo número 0175-08-2022.

3.1 Local e Amostragem

De janeiro a setembro de 2024 foram coletadas 120 amostras de 22 diferentes cultivares da espécie *Megathyrsus maximus* (Jacq.) B.K.Simon & S.W.L.Jacobs (*syn. Panicum maximum*) (Tabela 1), em diferentes estágios fenológicos, manejo e condições edafoclimáticas. As coletas ocorreram na Universidade Federal Rural do Rio de Janeiro (-22.774043, -43.687421, Seropédica, RJ; n=37), Universidade Federal de Lavras (-21.230499, -44.969889, Lavras, MG; n=37), Universidade Federal de São João Del Rei (-21.138305, -44.261094, São João Del Rei, MG; n=14) e na Universidade Federal de Viçosa (-20.774543, -42.858297, Viçosa, MG; n=32). Seropédica possui clima tropical úmido (Aw), segundo a classificação de Köppen-Geiger, com temperatura média anual de 24 °C e precipitação média de 1200 mm. Já Lavras e Viçosa possuem clima tropical de altitude (Cwa), com temperaturas médias de 19,4 °C e 19 °C, e precipitações médias anuais de 1530 mm e 1314 mm, respectivamente. Por sua vez, São João Del Rei apresenta clima subtropical moderado úmido (Cwb), com temperatura média de 19 °C e precipitação média anual de 1400 mm (Castro *et al.*, 1983; Campos *et al.*, 2007; Carvalho *et al.*, 2011).

No momento da coleta, as amostras foram identificadas, e registravam-se os dados referentes à altura, horário de coleta, estágio de maturação e localização. As amostras foram coletadas a 50% da altura inicial do dossel forrageiro, representando o estrato potencialmente pastejável (Barbosa *et al.*, 2007). Aproximadamente 500 g de material foi colhido em cada coleta e cortados em partículas de 2 a 3 cm, utilizando tesouras manuais. Em seguida, as amostras foram parcialmente desidratadas em estufa de ventilação forçada de ar a 55 °C (Método G-001/2), para obtenção da amostra seca ao ar (ASA; Detmann *et al.*, 2021). Após a desidratação, as amostras foram moídas a 2 mm e 1 mm, em moinho de facas, sendo então armazenadas em potes herméticos até as análises laboratoriais.

Tabela 1. Descrição e quantitativo das cultivares de *Megathyrsus maximus* coletadas.

Cultivar	Quantidade
Áries	1
Aruana	7
Atlas	2
Centenário	1
Colonião	6
Coloninho	2
Gatton Panic	1
Guiné	2
Hamilgrass	2
Makueni	1
Massai	14
Millenium	1
Miyagui	1
Mombaça	14
Paredão	7
Quênia	8
Tamani	13
Tanganica	1
Tanzânia	11
Tobiatã	8
Vencedor	6
Zuri	10

3.2 Amostragem Espectral

Ao longo das etapas de processamento físico das amostras, foram realizadas as amostragens espectrais, sendo: i) nas amostras frescas imediatamente após a picagem com tesoura (FR); ii) amostra após secagem em estufa (SC); iii) amostra seca e moída a 2 mm (SM2); iv) amostra seca e moída a 1 mm (SM1). Em cada etapa de preparo, foram coletadas seis varreduras espectrais em diferentes pontos aleatórios da amostra (Figura 1) utilizando o espectrômetro de infravermelho próximo portátil reflexivo (MyNIR, *Spectral Solutions*, São Paulo, Brasil), similar ao Innospectra NIR-S-G1 descrito por Berzaghi *et al.* (2021). O aparelho cobre uma faixa de absorbância de 900 a 1700 nm, utiliza uma lâmpada de 1,4 W com resolução óptica de 10-12 nm. Além disso, possui uma relação sinal:ruído de 5000:1 e um detector InGaAs de 1mm.

Antes de cada bateria de amostragens espectrais, o equipamento era calibrado com um padrão de refletância difusa de referência branca (Spectralon®, *Labsphere Inc.*, North Sutton, NH, EUA), composto por politetrafluoretileno (PTFE) sinterizado, material termicamente estável e quimicamente inerte, reconhecido por apresentar elevada refletância difusa (acima de 99%) e comportamento espectral uniforme em uma ampla faixa de comprimentos de onda, incluindo o infravermelho próximo (Martens; Naes, 1989; *Labsphere*, 2020). Seu uso como padrão de calibração permite corrigir variações na intensidade da fonte de luz, no detector e nas condições ambientais, minimizando interferências externas e ruído de fundo, permitindo que os espectros adquiridos reflitam ao máximo as propriedades ópticas da amostra.



Figura 1. Coleta de espectros nos quatro níveis de processamento: fresca (FR); seca (SC); seca e moída a 2 mm (SM2); seca e moída a 1 mm (SM1).

As coletas de espectros de amostras FR e SC, foram feitas em recipiente plástico branco, com seis cm de altura e oito cm de diâmetro. Já para as amostras SM2 e SM1, as coletas espectrais foram feitas em um recipiente redondo branco, com aproximadamente dois cm de altura e sete cm de diâmetro. Entre cada varredura espectral, as amostras foram misturadas e homogeneizadas. O sensor do dispositivo foi limpo entre cada leitura com algodão para amostras FR e pincel de cerdas macias para as demais amostras, garantindo a remoção de sujidades e prevenindo o embaçamento.

3.3 Composição Química e Digestibilidade *in vitro*

As amostras foram analisadas quanto aos teores de matéria seca (MS; método G-003/1), matéria orgânica (MO; método M-001/2), nitrogênio pelo método Kjeldahl (N; método N-001/2), fibra insolúvel em detergente neutro em autoclave (FDN; método F-002/2) sem o uso de alfa amilase e sulfito de sódio, FDN corrigida para cinzas (FDNc; método M-002/2) e fibra em detergente neutro indigestível após 288h (FDNi; método F-009/2), conforme descrito por Detmann *et al.* (2021).

Essas amostras foram, ainda, analisadas quanto à digestibilidade *in vitro* da matéria seca (DIVMS; método G-008/1) e digestibilidade *in vitro* da fibra insolúvel em detergente neutro (DIVFDN). A análise de DIVFDN seguiu os mesmos procedimentos de incubação realizados para DIVMS em incubadora Daisy II (*Ankom Technology Corporation Fairport, NY, USA*) complementados com a análise de FDN em autoclave (método F-002/2), conforme Detmann *et al.* (2021). Ambas as análises utilizaram inóculo preparado a partir de um *pool* de digesta

ruminal coletada de três novilhas da raça Girolando canuladas no rúmen, com peso vivo médio de $594,3 \pm 42,2$ kg, mantidas com livre acesso a silagem de sorgo, mistura mineral e alimentadas com 2,5 kg de concentrado/dia (20% PB). Os mesmos animais foram utilizados para as incubações *in situ* da análise de FDNi.

3.4 Produção de Metano *in vitro*

A produção de CH₄ foi avaliada *in vitro* em duplicatas e foram utilizados três frascos “brancos” (sem amostra) para correção da produção de gás. O líquido ruminal foi coletado de duas vacas da raça Holandês canuladas no rúmen, com peso vivo médio de $855,50 \pm 4,5$ kg, alimentadas com dieta à base de silagem de milho (relação volumoso:concentrado de 60:40), filtrado em três camadas de gaze e transportado em garrafas térmicas pré-aquecidas a 39 °C para uso como inóculo.

O meio de cultura foi preparado seguindo as recomendações de Theodorou *et al.* (1994). Posteriormente a mistura dos componentes, o meio foi mantido sob fluxo contínuo de CO₂ até atingir um pH entre 6,8 e 7,1. Ao alcançar o pH desejado, adicionou-se o líquido ruminal à solução na proporção de 3:1 (meio de cultura:líquido ruminal), seguido de uma nova aferição do pH. Foram adicionados 25 mL dessa solução tamponada aos frascos contendo cerca de 500 mg de amostras, sob fluxo de CO₂. Os frascos foram selados e incubados em agitador orbital (90 oscilações min⁻¹, 2 minutos a cada 2 horas) em sala climatizada a 39 °C. Após 24 horas de incubação, a produção de gás foi mensurada utilizando um aparelho vaso comunicante (Fedorah; Hrudey, 1983).

Para a análise de gases, aproximadamente 15 mL do gás do *headspace* dos frascos foi coletado com uma seringa de 20 mL e transferido para frascos de 6,8 mL com vácuo (*Exetainer*, *Labco Ltd.*, High Wycombe, Buckinghamshire, Reino Unido). Após a coleta, os frascos de incubação foram resfriados em banho de gelo para interromper o processo fermentativo, abertos, e os resíduos foram filtrados em papel filtro quantitativo (C41, Faixa preta, \varnothing 15 cm) com auxílio de bomba de vácuo. A concentração de CH₄ foi determinada por cromatografia gasosa (03 CG-FID *Agilent Technologies 7820A*, Santa Clara, EUA), conforme (Holtshausen *et al.*, 2009). Os resíduos das amostras retidos nos filtros foram secos em sala climatizada a 39 °C por 72 horas, e a matéria seca residual analisada. A produção de gás foi corrigida pelos valores médios dos frascos “brancos” de cada repetição. As emissões de CH₄ (mL g⁻¹ de matéria seca aparentemente digerida) foram estimadas a partir da degradação aparente da matéria seca (DAMS; g kg⁻¹), calculada pela equação:

$$\text{DAMS} = 1000 \times ((\text{MS}_i - \text{MS}_f) / \text{MS}_i)$$

onde MS_i e MS_f representam, respectivamente, a matéria seca incubada e residual (mg).

3.5 Calibração

Com o intuito de minimizar os efeitos da heterogeneidade de partículas e do ruído instrumental, foi calculado o espectro médio a partir de seis varreduras espectrais por amostra, em cada um dos níveis de processamento (FR, SC, SM2 e SM1), quantidade escolhida pela viabilidade de execução em campo. Sobre os espectros médios, foram aplicadas 99

combinações distintas de pré-processamentos espectrais, além do uso dos dados brutos. Foram aplicados os seguintes pré-processamentos: correção de linha de base, utilizada para eliminar deslocamentos sistemáticos; normalização, para ajuste da escala dos dados; e o filtro de Savitzky-Golay, com janelas de suavização de 7, 11, 13 e 15 pontos, ordens polinomiais de 2 e 3, derivadas de ordem 0, 1 e 2, e valores de delta de 1 e 2, com o objetivo de reduzir o ruído e aprimorar a resolução espectral. O processamento dos dados espectrais foi realizado por meio do módulo *nippy* no ambiente *Python* 3.12.6 (Torniainen *et al.*, 2020). A calibração das 100 combinações de dados espectrais (99 pré-processadas e uma bruta) foi feita por PLSR utilizando a função *PLSRegression* da biblioteca *scikit-learn*. A validação dos modelos foi conduzida pelo método *leave-one-out-cross-validation* (LOOCV). Para cada combinação espectral, foram obtidos o RMSEP, coeficiente de determinação da calibração (R^2_{train}), da validação (R^2_{test}), erro médio absoluto (MAE), inclinação (*slope*) e intercepto da regressão entre valores preditos e observados (Figura 2). Para cada nível de processamento das amostras, os resultados apresentados referem-se à calibração com o menor valor de RMSEP dentre as diferentes estratégias de pré-processamento avaliadas.

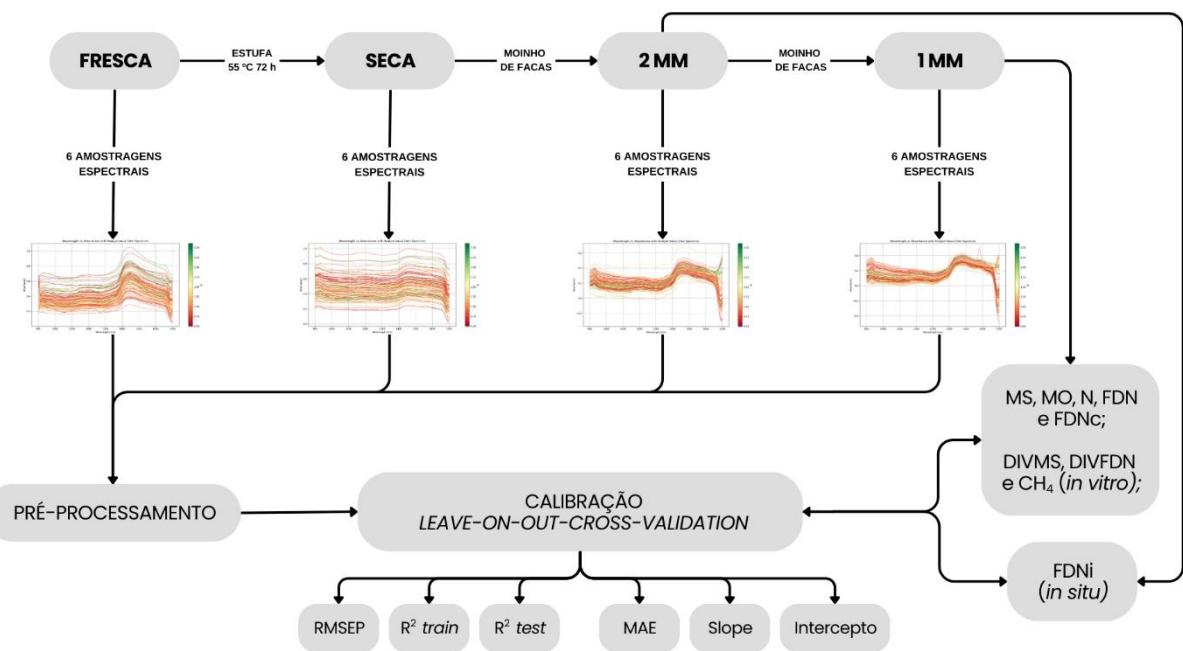


Figura 2. Fluxograma representando as etapas de preparo das amostras, aquisição espectral, pré-processamento e calibração dos modelos para predição da composição química e digestibilidade de forragens utilizando espectroscopia no infravermelho próximo (NIRS). As amostras foram analisadas em quatro níveis de processamento físico: fresca, seca, moída a 2 mm e moída a 1 mm, cada uma com seis amostragens espectrais coletadas. Após o pré-processamento dos dados espectrais, foi realizada a calibração dos modelos utilizando validação cruzada do tipo *leave-one-out*. Os modelos foram avaliados pelos parâmetros: erro quadrático médio da predição (RMSEP), coeficiente de determinação da calibração (R^2_{train}), coeficiente de determinação da validação (R^2_{test}), inclinação da reta (*Slope*), intercepto e erro médio absoluto (MAE). As variáveis de referência incluíram matéria seca (MS), matéria orgânica (MO), nitrogênio total (N), fibra insolúvel em detergente neutro (FDN), fibra insolúvel em detergente neutro corrigida para cinzas (FDNC), Fração indigestível da fibra insolúvel em detergente neutro (FDNi), digestibilidade *in vitro* da matéria seca (DIVMS), digestibilidade *in vitro* da fibra insolúvel em detergente neutro (DIVFDN), rendimento de metano *in vitro* (CH₄).

4 RESULTADOS

As variações da altura, composição química, digestibilidade e rendimento de metano das 120 amostras de *Megathyrsus maximus* (*syn. Panicum maximum*) utilizadas podem ser observadas na Tabela 2. A variabilidade é refletida pelo valor do desvio padrão e do coeficiente de variação, demonstrando sua amplitude, o que comprova sua heterogeneidade, condizentes com a espécie estudada.

Tabela 2. Máximo, mínimo, média, desvio padrão e coeficiente de variação da altura, composição bromatológica via úmida, digestibilidade e rendimento de metano *in vitro* das amostras coletadas (% da matéria seca, salvo indicação).

Variável	Máximo	Mínimo	Média	DP	CV (%)
Altura, cm	215,00	30,00	93,30	44,20	47,37
MS, % da MN	49,13	17,58	32,21	7,47	23,21
MO	95,28	87,09	91,24	1,91	2,09
N	2,61	0,50	1,21	0,49	40,41
FDN	75,93	57,54	67,90	4,05	5,96
FDNc	73,18	54,80	65,44	4,23	6,46
FDNi	42,56	12,25	24,27	7,44	30,67
DIVMS	85,94	50,17	65,10	8,92	13,70
DIVFDN	83,25	38,18	58,50	10,51	17,97
CH ₄ , mL/g MS	30,23	12,02	18,86	3,61	19,12

DP = Desvio padrão amostral; CV = Coeficiente de variação; MN = Matéria natural; MS = Matéria seca; MO = Matéria orgânica; N = Nitrogênio; FDN = Fibra insolúvel em detergente neutro; FDNc = FDN corrigida para cinzas; FDNi = FDN indigestível; DIVMS = Digestibilidade *in vitro* da MS; DIVFDN = Digestibilidade *in vitro* da FDN; CH₄ = Rendimento de metano *in vitro*.

A Figura 3 apresenta os 2.880 espectros brutos obtidos a partir das 120 amostras de *Megathyrsus maximus* (*syn. Panicum maximum*) nos diferentes graus de processamento físico. Os espectros revelam distintos padrões de intensidade de absorção, característicos das bandas espectrais em função do nível de processamento aplicado. Observa-se maior variabilidade visual nos espectros das amostras FR (Verde), seguidas pelas SC (Seco), pelas SM2 (M2) e, por fim, pelas amostras SM1 (M1), que exibiram os espectros mais consistentes. Os picos de absorbância foram mais intensos nas amostras FR, enquanto as amostras secas (SC, SM2 e SM1) apresentaram valores reduzidos de absorbância e menor variabilidade de intensidade. As médias das leituras espectrais por grau de processamento físico podem ser observadas na Figura 4, onde são evidenciadas as tendências gerais de absorbância, que facilita a identificação das intensidades das bandas de absorção e comparação entre os tratamentos.

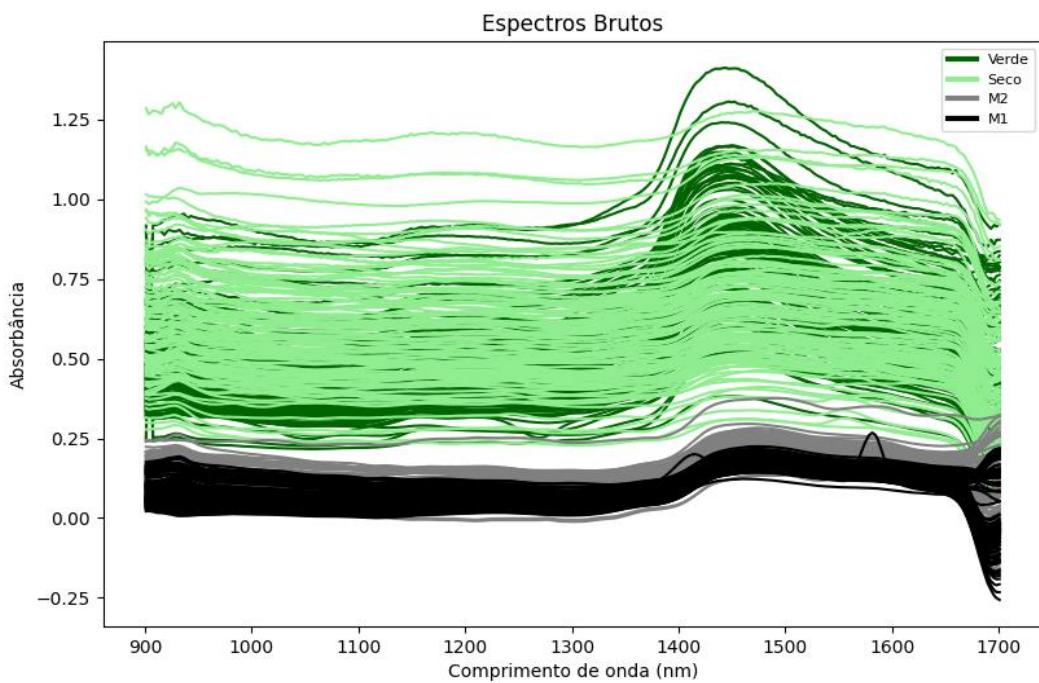


Figura 3. Conjunto de espectros brutos individuais na região NIR (900 a 1700 nm) das amostras para o conjunto de calibração e validação nos quatro níveis de processamento testados (Verde = FR; Seco = SC; M2 = SM2; M1 = SM1).

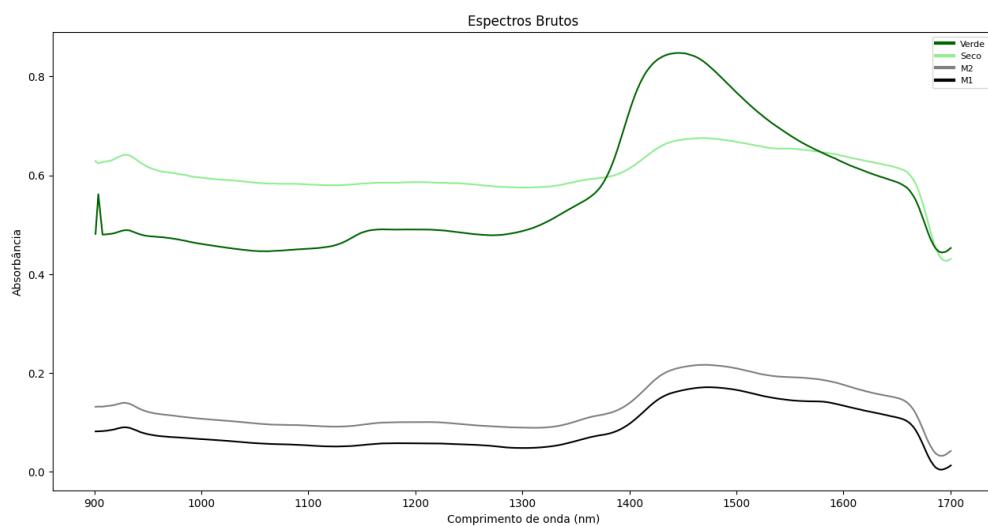


Figura 4. Média dos espectros brutos na região NIR (900 a 1700 nm) das amostras para o conjunto de calibração e validação nos quatro níveis de processamento testados (Verde = FR; Seco = SC; M2 = SM2; M1 = SM1).

O desempenho das calibrações multivariadas para cada variável analisada, nos diferentes níveis de processamento físico das amostras são expostos na Tabela 3.

Tabela 3. Performance dos modelos em função de nível de processamento para cada variável e nível de processamento.

Grau de processamento	Matéria seca (MS)						
	RMSEP	RMSEP%	R ² train	R ² test	MAE	Slope	Intercepto
Fresca	2,72	8,44	0,89	0,77	0,0187	0,93	2,32
Seca	3,37	10,46	0,76	0,66	0,0222	0,92	2,50
2 mm	2,85	8,85	0,87	0,76	0,0601	0,94	1,92
1 mm	2,74	8,51	0,82	0,75	0,0203	0,95	1,55
Matéria orgânica (MO)							
Fresca	1,26	1,38	0,50	0,32	0,0395	0,82	16,43
Seca	1,16	1,27	0,56	0,37	0,0116	0,80	18,33
2 mm	1,06	1,16	0,65	0,51	0,0123	0,88	10,63
1 mm	0,84	0,92	0,88	0,70	0,0007	0,84	14,54
Nitrogênio (N)							
Fresca	0,27	22,31	0,78	0,54	0,0120	0,85	0,20
Seca	0,23	19,01	0,74	0,59	0,0004	0,91	0,11
2 mm	0,14	11,57	0,93	0,84	0,0057	0,95	0,06
1 mm	0,16	13,22	0,98	0,80	0,0166	0,87	0,14
Fibra em detergente neutro (FDN)							
Fresca	2,42	3,56	0,70	0,49	0,0530	0,87	8,97
Seca	2,31	3,40	0,62	0,47	0,0202	0,87	9,17
2 mm	2,03	2,99	0,81	0,62	0,0230	0,88	7,80
1 mm	1,82	2,68	0,80	0,65	0,0076	0,87	8,99
FDN corrigida para cinzas (FDNc)							
Fresca	2,27	3,47	0,74	0,50	0,1477	0,88	7,91
Seca	2,41	3,68	0,63	0,47	0,0076	0,86	9,02
2 mm	2,1	3,21	0,79	0,61	0,0647	0,89	6,95
1 mm	1,92	2,93	0,75	0,66	0,0177	0,94	4,24
FDN indigestível (FDNi)							
Fresca	3,72	15,33	0,78	0,56	0,0362	0,88	2,95
Seca	3,55	14,63	0,73	0,60	0,0391	0,90	2,56
2 mm	3,78	15,57	0,83	0,71	0,1315	0,92	1,91
1 mm	2,74	11,29	0,89	0,77	0,0049	0,91	2,28
Digestibilidade <i>in vitro</i> da FDN (DIVFDN)							
Fresca	5,55	9,49	0,77	0,55	0,0339	0,85	8,92
Seca	5,19	8,87	0,70	0,58	0,0676	0,90	5,92
2 mm	4,67	7,98	0,80	0,66	0,0838	0,91	5,61
1 mm	3,53	6,03	0,94	0,82	0,1008	0,92	4,75
Digestibilidade <i>in vitro</i> da MS (DIVMS)							
Fresca	5,17	7,94	0,67	0,47	0,1264	0,88	8,25
Seca	4,94	7,59	0,66	0,51	0,0684	0,90	6,87
2 mm	4,40	6,76	0,79	0,65	0,0309	0,90	6,83
1 mm	3,70	5,68	0,97	0,75	0,2445	0,83	11,18
mL de CH ₄ /g de MS digerida <i>in vitro</i> (CH ₄)							
Fresca	2,18	11,56	0,62	0,40	0,0322	0,79	3,99
Seca	2,41	12,78	0,41	0,31	0,0470	0,90	2,01
2 mm	2,08	11,03	0,65	0,45	0,0717	0,81	3,69
1 mm	2,09	11,08	0,55	0,45	0,0098	0,92	1,54

RMSEP = Raiz do erro quadrático médio de predição; RMSEP% = Raiz do erro quadrático médio de predição em % do valor médio observado; R² train = Coeficiente de determinação da calibração; R² test = Coeficiente de determinação da validação; MAE = Erro médio absoluto; Slope = inclinação.

A performance preditiva dos modelos para MS variou conforme o grau de processamento físico (Figura 5). Amostras FR apresentaram melhor combinação entre acurácia e precisão, com R^2 *test* de 0,77 e o menor MAE (0,0187), além de um RMSEP de 2,72 e RMSEP% de 8,44, o elevado R^2 *train* (0,89) e o *slope* próximo de 1 (0,93) reforçam a qualidade do ajuste do modelo. Amostras SM1 e SM2, apresentaram desempenho semelhante, com R^2 *test* de 0,75 e 0,76, respectivamente, e RMSEP% entre 8,5 e 8,8. O tratamento SM1 resultou em leve melhora no erro absoluto (MAE de 0,0203 contra 0,0601 de SM2) e em valores de intercepto menores (1,55 contra 1,92), indicando melhor alinhamento entre os valores observados e preditos. Por sua vez, amostras SC apresentaram os piores índices de desempenho, com R^2 *test* de 0,66 e o maior RMSEP% (10,46), menor R^2 *train* (0,76).

Para MO, o tratamento SM1 apresentou os melhores indicadores de desempenho em comparação as demais, obtendo valores de RMSEP e MAE mais baixos (0,84 e 0,0007, respectivamente) e valores e R^2 *train* e R^2 *test* mais elevados (0,88 e 0,70), além de um *slope* superior (0,84). Seguido de SM2 com R^2 *test* de 0,51 e RMSEP de 1,06, e menor intercepto (10,63) em comparação a SM1. Já amostras SC e FR apresentaram os menores R^2 *test* (0,37 e 0,32, respectivamente), com RMSEP% superiores a 1,25 e interceptos elevados (18,33 e 16,43), indicando menor capacidade de predição da MO nesses tratamentos. O modelo SC obteve um MAE inferior ao FR (0,0116 contra 0,0395), e ambos os tratamentos apresentaram alta dispersão dos resíduos, refletindo baixa precisão nas predições. De um modo geral, o maior nível de processamento acarretou melhor desempenho na calibração para este parâmetro (Figura 6).

A calibração para N apresentou melhor desempenho em SM2, com R^2 *train* de 0,93 e R^2 *test* de 0,84, evidenciando alto poder explicativo tanto no conjunto de calibração quanto no de validação. Esse tratamento também apresentou o menor RMSEP (0,14) e RMSEP% (11,57), além de MAE baixo (0,0057) e um *slope* próximo do ideal (0,95), com intercepto de apenas 0,06. Amostras SM1 apresentaram um R^2 *train* superior (0,98), o R^2 *test* foi um pouco inferior (0,80), e o RMSEP aumentou para 0,16. O MAE também foi maior (0,0166), o que pode sugerir maior erro frequente na predição nesse tratamento. Amostras SC apresentaram R^2 *test* de 0,59 e RMSEP de 0,23, mostrando uma acurácia moderada. O modelo apresentou boa linearidade (*slope* = 0,91) e baixo MAE (0,0004), mas o RMSEP% elevado (19,01). As amostras FR, apresentaram o menor desempenho, com R^2 *test* de 0,54 e o maior RMSEP (0,27) e RMSEP% (22,31), além de intercepto de 0,20 (Figura 7).

A predição dos teores de fibra demonstrou que a moagem das amostras, especialmente em níveis mais finos, melhora sistematicamente a acurácia e precisão dos modelos, independentemente da fração de fibra analisada (FDN, FDNC ou FDNI), com valores de RMSEP e MAE menores, associados a maiores valores de R^2 *train* e R^2 *test* e *slope* mais próximos de 1 (Figuras 8, 9 e 10). Os melhores resultados foram observados nas amostras SM1, que apresentaram o menor RMSEP (1,82, 1,92 e 2,74 e para FDN, FDNC e FDNI, respectivamente) e RMSEP% (2,68, 2,93 e 11,29), além de R^2 *test* de 0,65, 0,66 e 0,77 e *slope* de 0,87, 0,94 e 0,91, respectivamente, com bom alinhamento dos dados preditos e observados. Para FDN amostras SM2 também apresentaram bons resultados, com R^2 *test* de 0,62 e RMSEP de 2,03. Em contraste, os modelos com amostras FR e secas SC tiveram desempenho inferior (R^2 *test* de 0,49 e 0,47, respectivamente), com maiores erros de predição ($RMSEP \geq 2,31$) e interceptos mais altos, refletindo maior variabilidade e menor ajuste. Para FDNC a moagem a 2 mm também mostrou resultados medianos (R^2 *test* = 0,61 e RMSEP = 2,10). Novamente, amostras FR e SC apresentaram os piores desempenhos, com R^2 *test* de 0,50 e 0,47, respectivamente. No entanto, amostras FR apresentaram bons valores preditivos,

principalmente para FDNi, com RMSEP de 3,72, R^2 *train* de 0,74, R^2 *test* igual a 0,56 e *slope* de 0,88.

Assim como nas análises de fibra, a predição da digestibilidade *in vitro* também apresentou desempenho superior no processamento SM1, com menores valores de RMSEP, e altos R^2 *train* e R^2 *test* (Figuras 11 e 12). A DIVFDN obteve valores de 3,53, 0,94 e 0,82, respectivamente. Além disso, o *slope* (0,92) mostrou bom alinhamento entre valores preditos e observados, e o intercepto foi o mais baixo (4,75). Amostra SM2 também apresentaram desempenho mediano (R^2 *test* = 0,66 e RMSEP = 4,67), embora inferiores aos resultados da moagem mais fina. Amostras SC e FR apresentaram desempenho limitado, com R^2 *test* < 0,60 e RMSEP > 5,0. Enquanto DIVMS obteve 3,70, 0,97 e 0,75 para RMSEP, R^2 *train* e R^2 *test*, respectivamente. No entanto, esse tratamento apresentou os maiores valores de MAE (0,2445), o que significa que pode haver maior erro sistemático embutido no modelo. Amostras SM2 resultaram em bom equilíbrio entre precisão e acurácia (R^2 *test* = 0,65, RMSEP = 4,40). Já as amostras FR e SC tiveram desempenho mais fraco, com R^2 *test* de 0,47 e 0,51, respectivamente, e RMSEP acima de 4,90.

Já para o rendimento de CH₄, os tratamentos SM1 e SM2 apresentaram os melhores desempenhos (Figura 13), com baixos RMSEP (2,09 e 2,08, respectivamente), valores medianos de R^2 *train* (0,65 e 0,55), R^2 *test* (0,45 para ambos). Valores semelhantes foram observados para o tratamento FR com RMSEP de 2,18, R^2 *train* de 0,62 e R^2 *test* de 0,40. Além disso, o tratamento FR ainda apresentou um menor valor de MAE comparado ao tratamento SM2 (0,0322 contra 0,0717).

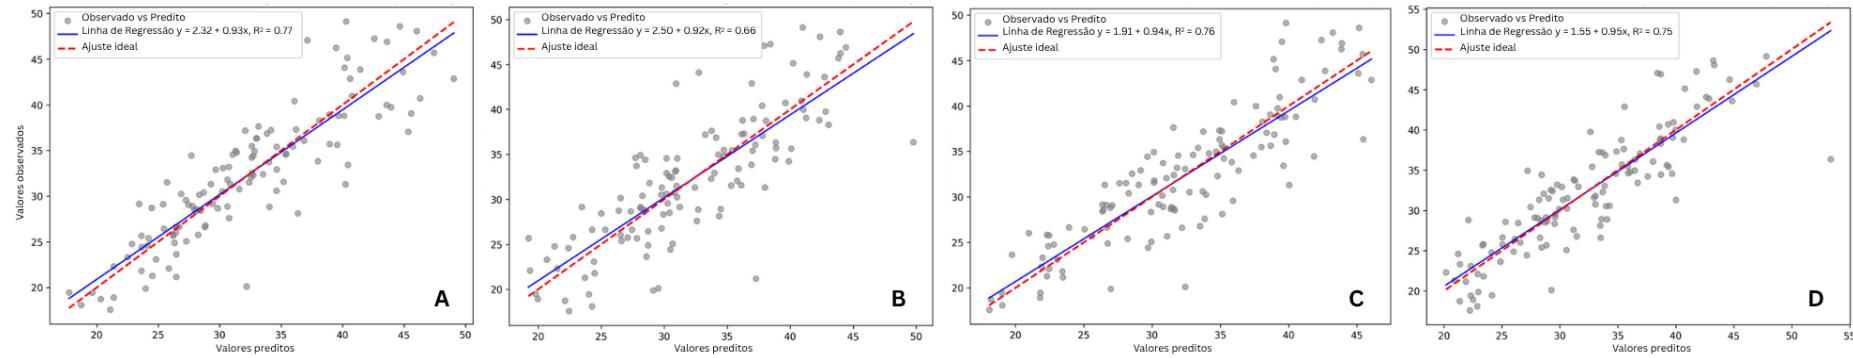


Figura 5. Gráficos de dispersão entre os valores preditos e observados para matéria seca nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

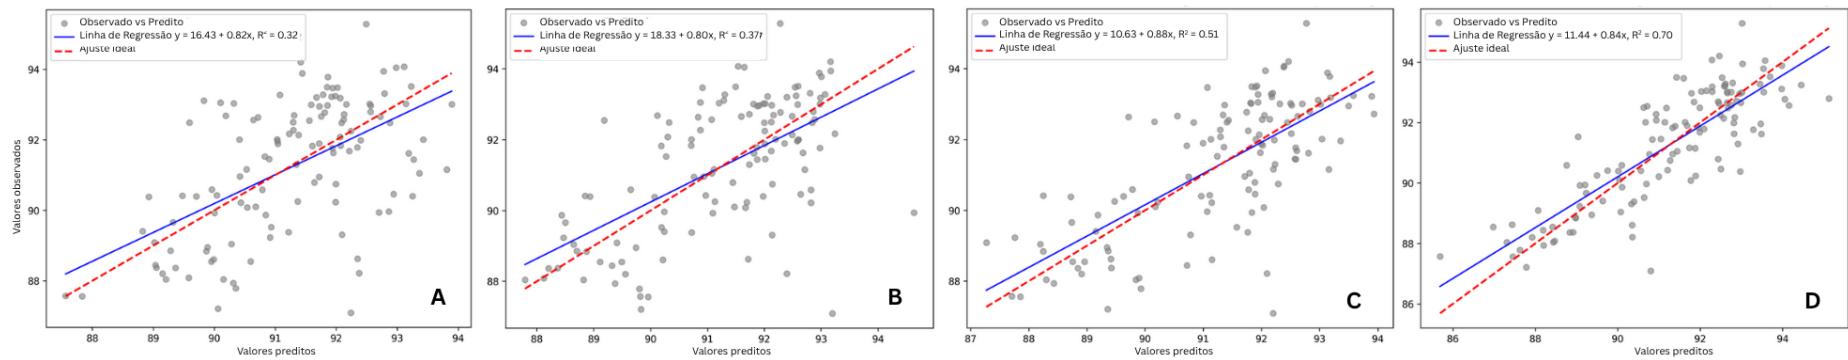


Figura 6. Gráficos de dispersão entre os valores preditos e observados para matéria orgânica nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

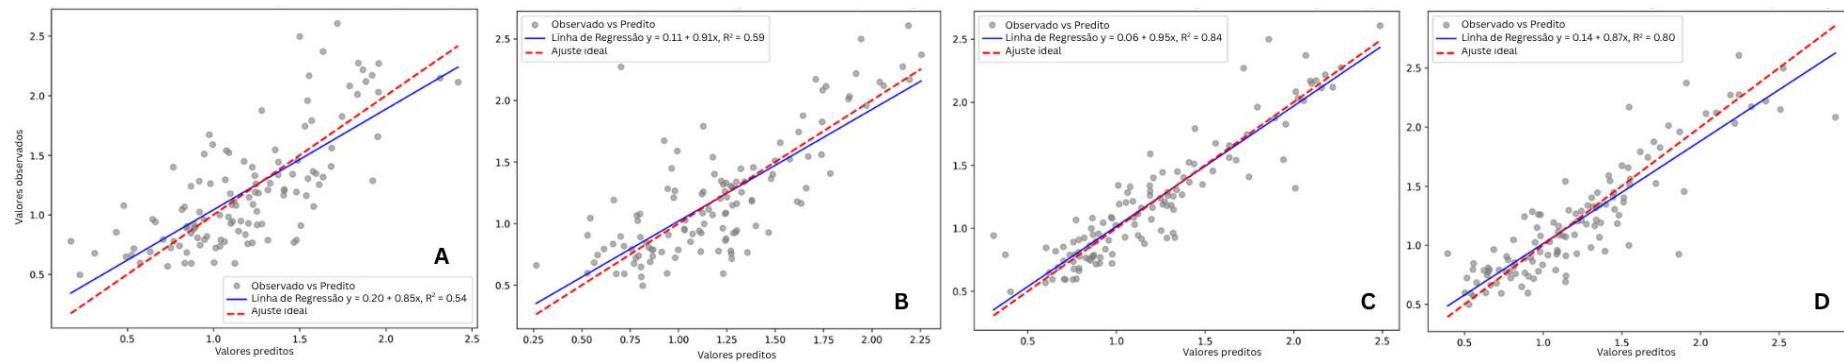


Figura 7. Gráficos de dispersão entre os valores preditos e observados para nitrogênio nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

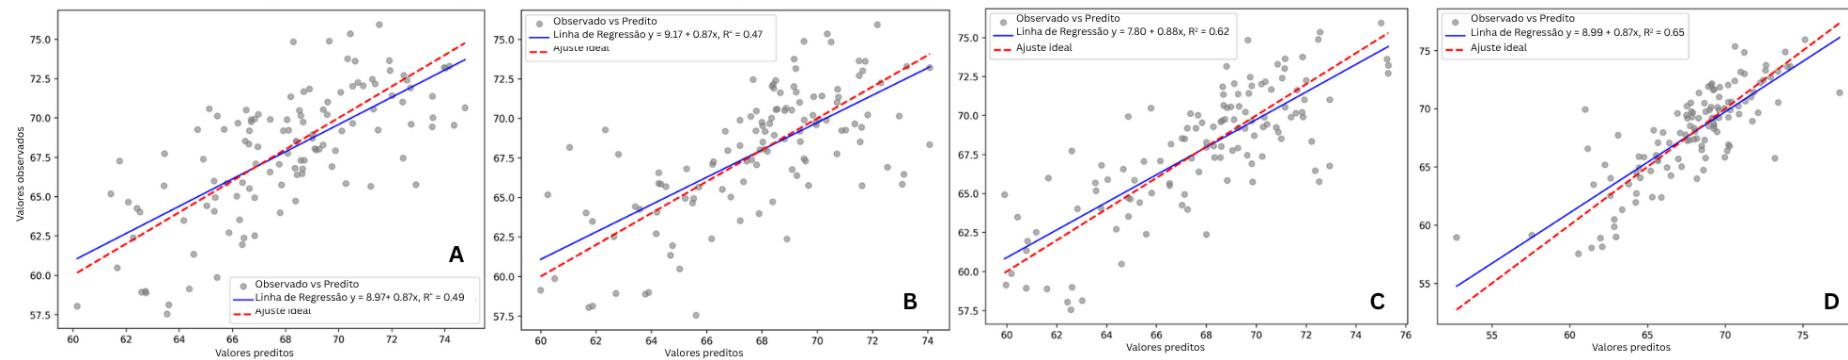


Figura 8. Gráficos de dispersão entre os valores preditos e observados para fibra insolúvel em detergente neutro nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

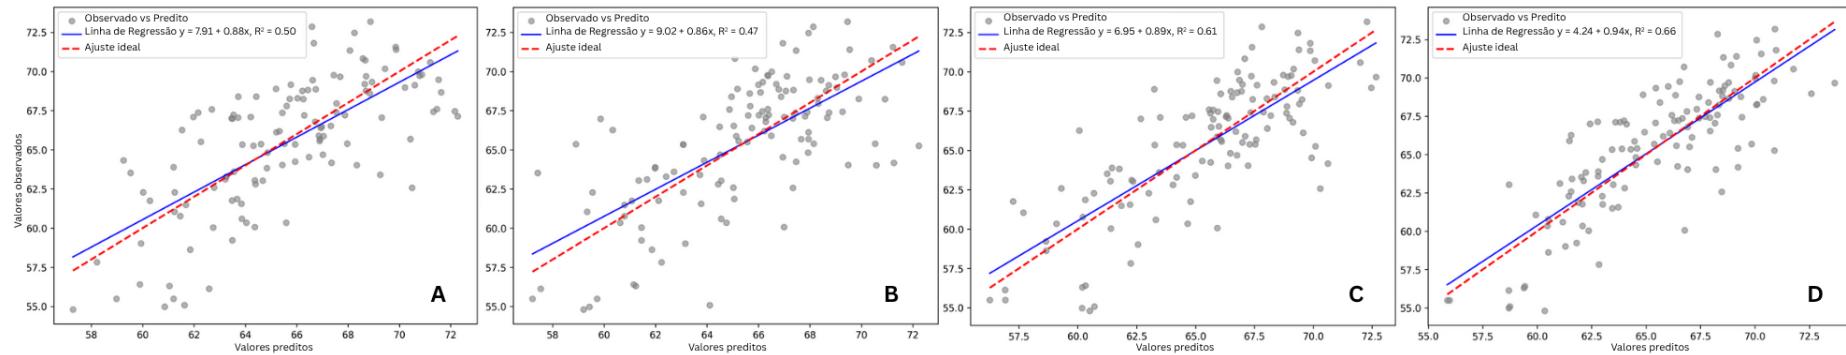


Figura 9. Gráficos de dispersão entre os valores preditos e observados para fibra insolúvel em detergente neutro corrigida para cinzas nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

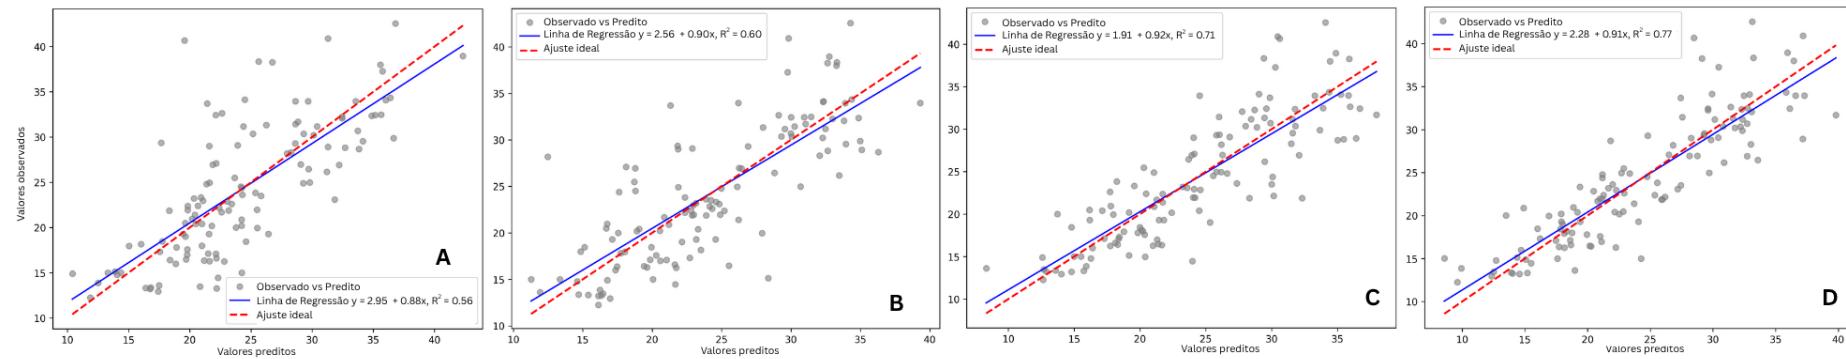


Figura 10. Gráficos de dispersão entre os valores preditos e observados para fração indigestível da fibra insolúvel em detergente neutro nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

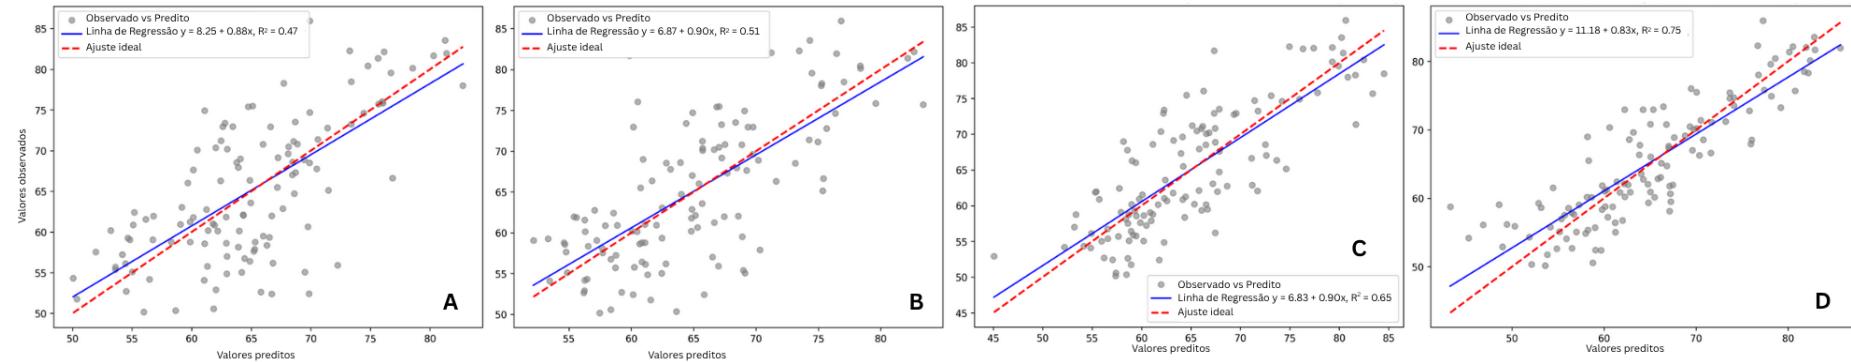


Figura 11. Gráficos de dispersão entre os valores preditos e observados para digestibilidade *in vitro* da matéria seca nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

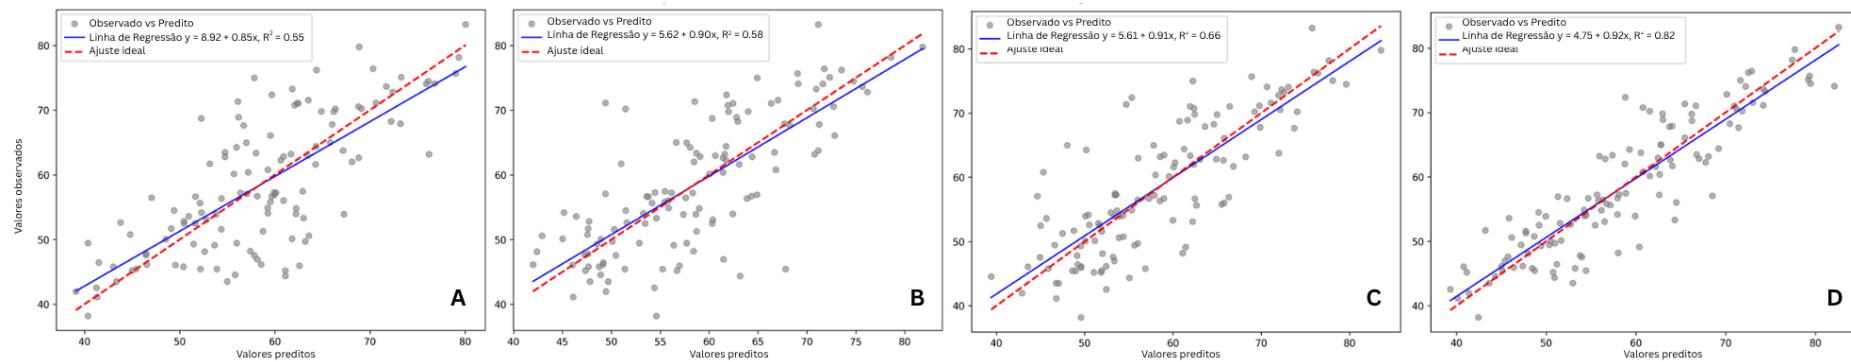


Figura 12. Gráficos de dispersão entre os valores preditos e observados para digestibilidade *in vitro* da fibra insolúvel em detergente neutro nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

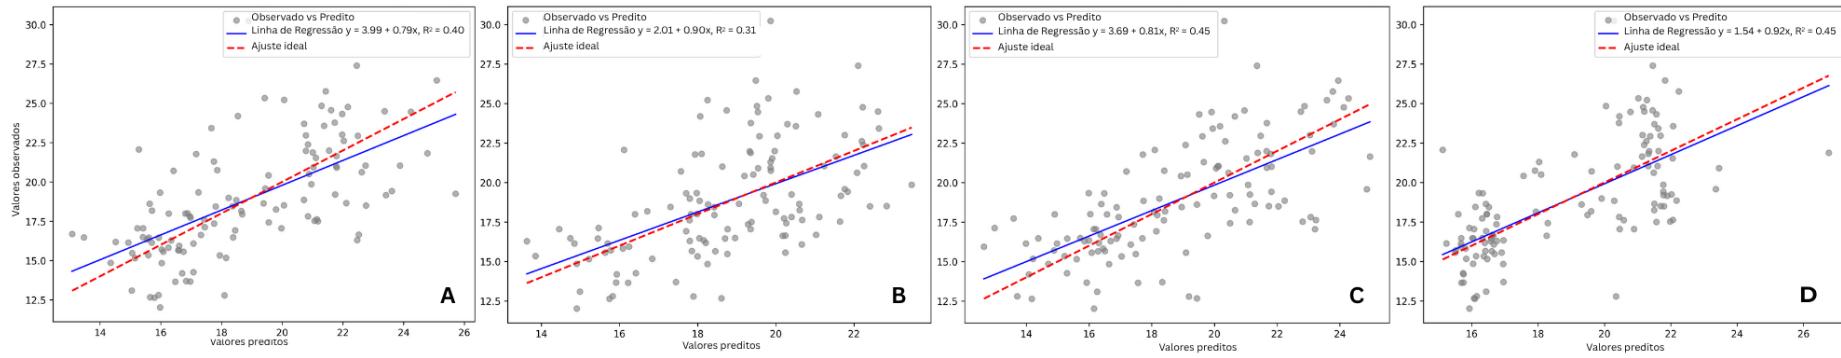


Figura 13. Gráficos de dispersão entre os valores preditos e observados para fração indigestível da fibra insolúvel em detergente neutro nos diferentes níveis de preparo físico das amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul indica a regressão linear obtida (com equação e coeficiente de determinação R^2), enquanto a linha vermelha tracejada representa o ajuste ideal 1:1. Os pontos cinza correspondem às amostras utilizadas na calibração e validação do modelo.

5 DISCUSSÃO

O presente estudo objetivou avaliar a capacidade preditiva de um espectrômetro NIR portátil em determinar o valor nutritivo de amostras de *Megathyrsus maximus* (*syn. Panicum maximum*) em diferentes graus de processamento, buscando avaliar o conceito de aplicação de um equipamento portátil de baixo custo com processamento mínimo das amostras. A hipótese é de que seria possível estimar o valor nutritivo da forragem a partir dos espectros de amostras minimamente processadas. Essa prática pode ser determinante em sistemas de produção de ruminantes em pastejo, visto que, conhecer o valor nutritivo da forragem em tempo real é essencial para aumentar a eficiência alimentar e produtividade dos animais, permitindo ajustes dietéticos e de manejo adequados (Bell; Mereu; Davis, 2018; Ferraro *et al.*, 2012).

Apesar dos melhores desempenhos de calibração terem sido, de modo geral, observados em amostras com maiores níveis de processamento e partículas mais homogêneas (SM1 e SM2), os resultados obtidos para as amostras FR demonstram o potencial de utilização do pNIRS com o mínimo de processamento. Em parâmetros como MS, por exemplo, o RMSEP e MAE foram 0,73% e 7,88% menores em amostras FR quando comparados a SM1, respectivamente. Para CH₄, foi observada uma pequena melhora nos valores de RMSEP entre amostras FR e SM1 (4,59%). Embora os valores de R² nas amostras FR sejam inferiores aos obtidos nos maiores níveis de processamento (SM1 e SM2), foram encontrados altos R², sugerindo a utilização para aplicações práticas, como no caso do FDNi que apresentou uma melhora de 14,10% no desempenho entre amostras FR e SM1. De forma prática, essa melhoria de desempenho pode não compensar se considerada a agilidade, simplicidade e custo reduzido associados à análise direta de amostras frescas, além do benefício da formulação dietética em tempo real, o que torna viável o uso do NIR portátil para avaliações rápidas no campo.

A altura de manejo recomendada em lotação rotativa para os cultivares Mombaça e Massai, mais representativos no conjunto de amostras (Tabela 1), é de 85 e 55 cm, respectivamente (Rodrigues *et al.*, 2016; Carvalho *et al.*, 2017). Valores extremos como de 215 cm são importantes para a caracterização espectral com plantas em estágio avançado de maturação. O capim Massai apresenta digestibilidade média de 59%, enquanto o capim Mombaça apresenta 57% de DIVMS (Pereira *et al.*, 2021). Sendo assim, os valores de DIVMS encontrados também evidenciam a variabilidade de amostras coletadas. A MO mostrou uma variação de 8%, suficiente para representar a estabilidade desse parâmetro em forragens, já que o teor de MM é relativamente constante em forrageiras tropicais. A variação no teor de FDN evidenciam as diferenças estruturais que afetam tanto a digestibilidade quanto os espectros. O valor médio de FDN em capim Massai é de aproximadamente 75%, enquanto Mombaça possui cerca de 73% (Fernandes *et al.*, 2014). De um modo geral, as variações de altura, digestibilidade e composição satisfazem níveis básicos para confecção de um modelo robusto para avaliação do equipamento NIRS portátil com amostras obtidas em diferentes estágios vegetativos e valores nutritivos.

Os espectros brutos das amostras apresentados na Figura 3, mostraram padrões distintos dependendo do nível de processamento aplicado. Uma maior variabilidade visual foi observada nas amostras FR, seguidas pelas amostras SC, SM2 e SM1. Importante considerar que o fator umidade possui maior interferência nas amostras FR, a apesar de todas as outras amostras apresentarem umidade residual, a maior interferência observada nas amostras SC

provavelmente foi oriunda do espalhamento da luz. O fato de as amostras FR e SC não estarem moídas constituiu uma limitação nas leituras, em virtude da superfície irregular da amostra limitar a cobertura total do detector do equipamento (Figura 1). A morfologia da superfície e o índice de refração afetam as propriedades de espalhamento dos materiais sólidos (Dias; Nunes; Borba, 2023).

Foi observada maior variação na região espectral de 1450 nm (Figura 4), que está relacionado ao primeiro sobretom da ligação OH, que corresponde ao teor de umidade da amostra (Cozzolino; Fassio; Gimenez, 2001). Esse pico se estende até os 1500 nm, que corresponde ao primeiro sobretom da ligação NH, relacionado ao teor de nitrogênio. Já a região espectral de 1685 nm apresenta picos menos intensos correlacionados ao primeiro sobretom da ligação CH, que nessa região está relacionado ao teor de proteína da amostra (Dias; Nunes; Borba, 2023). Já os leves picos observados na região de 1198 nm estão relacionados ao segundo sobretom da ligação CH que se correlacionam com lipídeos (Murray, 1986) esse pico menos proeminente foi esperado, visto que gramíneas tropicais não possuem quantidades expressivas no teor de lipídeos. Os picos na região de 1676 nm estão associados à digestibilidade da FDN, correlacionado ao teor de FDNi (Krizsan *et al.*, 2015).

O melhor modelo preditivo para MS foi observado na calibração com amostras FR. Esses valores podem ser explicados pelo fato dessa amostra ainda conter toda a água do material, enquanto os demais tratamentos estimaram o teor de MS em amostras as quais a água já havia sido removida. A aplicação de equipamentos portáteis similares ao utilizado no presente estudo para a estimativa da MS de forragens frescas já é, inclusive, aplicada em nível de campo (Crocombe, 2018; Foskolos *et al.*, 2015; Lobos; Moscoso; Pavez, 2019). Apesar de ser um parâmetro facilmente mensurado por outras metodologias como micro-ondas e koster (Pino; Heinrichs, 2014), estas metodologias não quantificam a água total presente no material. Logo a estimativa do teor de MS com equipamento NIR pode ser menos laboriosa, mais rápida e mais acurada, destacando a aplicação demonstrada no nosso estudo, ainda não reportada na literatura para gramíneas tropicais.

O teor de MO, estimado indiretamente a partir do teor de cinzas (MM), é comumente reportado com baixa acurácia quando mensurado por espectroscopia NIR, uma vez que os minerais não possuem bandas de absorção características nessa faixa espectral (Reddersen; Fricke; Wachendorf, 2013). Além disso, a presença de contaminantes como o solo pode interferir na linha de base do espectro, especialmente na região entre 1100 e 1300 nm (Paul, 1990), dificultando ainda mais a calibração, sobretudo em amostras frescas. Os piores resultados foram obtidos para as amostras FR, com maiores RMSEP e MAE, e menores R^2 *train* e R^2 *test*. Por outro lado, melhor desempenho preditivo foi observado nas amostras SM1, com redução de 33,33% no valor RMSEP e 98,23% no valor de MAE. Esses resultados reforçam que o aumento no nível de processamento da amostra contribui significativamente para a melhoria da qualidade dos modelos de predição de MO por NIRS.

O melhor desempenho preditivo para N foi observado em amostras SM2, com menor valor de RMSEP e R^2 *train*. Porém, amostras FR também apresentaram bons resultados, com alto valor R^2 *train* e baixo RMSEP. Além disso, os RMSEP% e o MAE para amostras FR são aceitáveis, especialmente considerando a ausência de preparo laboratorial e o *slope* próximo de 1 reforça a tendência linear adequada da calibração. Comparando os resultados obtidos neste estudo com os de Oliveira *et al.* (2024), observa-se que o modelo desenvolvido a partir de amostras FR apresentou desempenho superior na etapa de calibração, com R^2 *train* 5,38% maior, além de uma expressiva redução de 84% no RMSEP. Esses resultados indicam maior acurácia e precisão do modelo proposto neste trabalho, mesmo com o uso de amostras

minimamente processadas. No entanto, o modelo de Oliveira *et al.*, (2024) demonstrou melhor desempenho na validação externa, com R^2 *test* 12,09% superior, sugerindo maior capacidade de generalização. Assim, embora a moagem aumente a acurácia do modelo, amostra frescas se mostram promissoras para estimativas rápidas de teor de N, o que pode ser útil em avaliações práticas no campo.

A predição do teor de FDN por pNIRS em amostras frescas apresenta desafios adicionais por se tratar de um componente multifatorial, cuja determinação analítica é impactada tanto pela metodologia laboratorial quanto pelas variações nas ligações químicas das amostras. Os resultados obtidos neste estudo demonstram valores ligeiramente inferiores aos de alguns estudos prévios. Por exemplo, ao utilizar um pNIRS em amostras frescas, Dias, Nunes e Borba (2023) obtiveram um R^2 *train* 10% superior e menor RMSEP, o que indica maior precisão em suas calibrações. Da mesma forma, Oliveira *et al.* (2024) verificaram desempenho levemente superior ao analisar amostras secas e moídas com pNIRS, registrando um RMSEP 39,6% menor e um R^2 *train* 6,25% superior ao deste trabalho. Já Hart *et al.* (2020), avaliando forragens frescas com NIRS de bancada, observaram R^2 *train* 17% superior, com MAE% de 3,76%. Vale destacar que as calibrações para FDNC costumam apresentar melhor desempenho por excluírem a fração mineral, cuja ausência de absorção na região NIR reduz a interferência espectral. No presente estudo, apesar do FDNI ter apresentado maior RMSEP, seus R^2 foram mais elevados, reforçando o potencial do modelo para aplicações práticas. A literatura já reconhece o uso eficaz do NIRS, especialmente de bancada, na predição do FDNI em forragem fresca e silagem de gramíneas (Krizsan *et al.*, 2015; Nousiainen *et al.*, 2004), o que corrobora a aplicabilidade da técnica também em dispositivos portáteis, como demonstrado no presente estudo.

Os resultados de calibração para DIVMS e DIVFDN demonstraram melhor desempenho nos modelos desenvolvidos com amostras SM1, possivelmente devido à maior homogeneidade física do material. No entanto, os valores obtidos para as amostras FR evidenciam a viabilidade do uso do pNIRS mesmo com mínimo processamento, apresentando R^2 *train* e R^2 *test* moderados. As métricas obtidas para FR foram semelhantes às encontradas por Dias, Nunes e Borba (2023), com R^2 *train* de 0,67 e 0,71 e RPD de 1,72 e 2,84 para DIVMS e DIVFDN, respectivamente (RPD = DP/RMSEP, sendo valores entre 1,5 e 2,5 geralmente considerados aceitáveis para triagem). Embora a capacidade preditiva seja classificada como regular, os modelos de DIVMS com erro médio de 2,20% (Andrés *et al.*, 2005) podem apresentar maior precisão do que o uso de tabelas químicas fixas, que não consideram a variabilidade entre amostras reais (Hart *et al.*, 2020). A espectroscopia NIR contribui para reduzir custos e tempo analítico, além de fornecer informações mais precisas para a formulação de dietas e o manejo nutricional. O melhor desempenho observado para a DIVFDN pode ser atribuído à sua maior especificidade, enquanto a DIVMS é influenciada por múltiplos constituintes da amostra, o que tende a dificultar a modelagem preditiva.

A produção de CH₄ entérico em ruminantes representa uma perda significativa de energia, variando entre 2% e 12% da energia bruta consumida, conforme a dieta e a eficiência da fermentação ruminal (Johnson; Johnson, 1995). Essa perda energética resulta da formação de CH₄ a partir da redução do CO₂ por H₂ durante a fermentação microbiana no rúmen, competindo com vias mais eficientes de aproveitamento energético, impactando negativamente o desempenho animal (Moss *et al.*, 2000; Ungerfeld, 2020). No presente estudo, embora os modelos preditivos para CH₄ com amostras FR tenham apresentado R^2 inferiores aos obtidos em amostras mais processadas (SM1 e SM2), com redução de 21% e 17% em relação a SM1 e SM2, respectivamente, o valor de RMSEP foi 17,1% inferior ao reportado por Norman *et al.* (2020) com uso de NIR de bancada em amostras secas e moídas. Apesar do RPD também ter

sido inferior nas amostras FR (1,66 contra 3,10, uma diferença de 46,5%), o desempenho observado está alinhado ao encontrado por Dias, Nunes e Borba (2023) e Sun et al. (2022), que também relataram explicações da variabilidade na emissão de metano de até 53% com uso da técnica. Considerando a elevada variabilidade biológica associada à produção de CH₄ e a complexidade das vias metabólicas envolvidas, os resultados obtidos reforçam o potencial da pNIRS como ferramenta não invasiva e viável para monitoramento rápido da eficiência fermentativa e das perdas energéticas dos ruminantes, especialmente em sistemas tropicais a pasto. Há uma defasagem de estudos conduzidos em forragens frescas com aparelhos portáteis que mensurem essa característica.

A precisão da leitura pelo NIRS pode ser comprometida por diversos fatores, sendo os mais comuns o tamanho de partícula, o preparo das amostras, o teor de umidade e a dispersão da luz (Burns; Ciurczak, 2007; Siesler *et al.*, 2008). A umidade é um dos principais componentes das forragens e representa um desafio para análises por NIRS, uma vez que a água apresenta fortes bandas de absorção, interferindo na análise. Isso explica em grande parte o natural aumento de desempenho para SC, SM2 e SM1 em relação a FR. Os diferentes tamanhos de partículas podem causar espalhamento da luz, alterando a expressão dos picos de absorção. O aumento da partícula promove aumento do log (1/R), devido ao maior percurso óptico, causando deslocamento da linha de base (Dhanoa *et al.*, 2023; Tian *et al.*, 2021). Logo, esses fatores podem sobrepor bandas de absorção, prejudicando a interpretação dos dados. Por isso, essas variações são reconhecidas como fatores críticos de interferência que devem ser monitorados e controlados (Santana *et al.*, 2019; Koehler *et al.*, 2000). Porém, a aplicação em amostras frescas ou com o menor nível de processamento é importante pois torna a tecnologia passível de utilização no campo, com resultados em tempo real (Bell; Mereu; Davis, 2018).

6 CONCLUSÃO

Conclui-se que, o equipamento pNIRS mostrou potencial para futuras calibrações robustas, inclusive em amostras frescas de *Megathyrsus maximus* (syn. *Panicum maximum*), principalmente para as variáveis MS, N, FDNi. O processamento a 1 mm é vantajoso para variáveis mais complexas, como a digestibilidade, FDN e CH₄. Considerando que o N e FDN são informações de alta relevância para a nutrição de animais em pastejo, o desenvolvimento de calibrações para equipamentos NIR portáteis minimamente enviesadas, pode ser mais eficiente que o uso de valores médios tabelados. Isso evidencia o potencial do pNIRS para análise rápida e precisa de forragens em diferentes níveis de processamento, especialmente em condições práticas de campo.

7 CONSIDERAÇÕES GERAIS

Maiores acuráncias são observados quando a amostra possui maior nível de processamento. Com exceção da MS, todos os tratamentos com amostras moídas a 1 mm obtiveram menores valores de RMSEP e maiores valores de R^2 tanto para calibração, quanto validação.

Apesar do tratamento FR não ter apresentado métricas estatísticas superiores aos tratamentos com maior nível de processamento, todos os resultados obtidos, demonstram a capacidade do aparelho NIRS em predizer o valor nutritivo da gramínea *Megathyrsus maximus* com o mínimo de processamento, suportando a futura aplicação da técnica a nível de campo, com erros consideravelmente menores em relação a valores tabelados. Os teores de MS, N e FDNi apresentam bons valores preditivos. A MS demonstrou uma ótima aplicabilidade em material fresco, enquanto N e FDN apresentaram resultados com potencial de incremento. Assim, demonstra possível aplicabilidade do aparelho para planejamento de dietas de forma eficaz, visto que estes são parâmetros de extrema importância na formulação de dietas para ruminantes.

Sendo assim, os resultados obtidos demonstram que o pNIRS é eficaz na análise de forragem com níveis mínimos de processamento, sendo possível obter calibrações precisas e com erros aceitáveis. No entanto, o processamento de 1 mm mostrou-se mais confiável para a calibração de parâmetros como FDN, DIVMS e DIVFDN, proporcionando a melhor combinação entre precisão e confiabilidade. O estudo reforça a viabilidade do uso do pNIRS para análises rápidas e eficientes da forragem, com impacto direto em práticas de manejo e formulação de dietas, principalmente quando se busca reduzir o tempo e os custos de processamento das amostras.

8 REFERÊNCIAS BIBLIOGRÁFICAS

ACOSTA, J. J.; CASTILLO, M. S.; HODGE, G. R.. Comparison of benchtop and handheld near-infrared spectroscopy devices to determine forage nutritive value. **Crop Science**, [S.L.], v. 60, n. 6, p. 3410-3422, 7 out. 2020. Wiley. <http://dx.doi.org/10.1002/csc2.20264>.

AGELET, Lidia Esteve; HURBURGH, Charles R.. A Tutorial on Near Infrared Spectroscopy and Its Calibration. **Critical Reviews In Analytical Chemistry**, [S.L.], v. 40, n. 4, p. 246-260, 29 out. 2010. Informa UK Limited. <http://dx.doi.org/10.1080/10408347.2010.515468>.

ALOMAR, D. *et al.* Prediction of the Composition of Fresh Pastures by Near Infrared Reflectance or Interactance-Reflectance Spectroscopy. **Chilean journal of agricultural research**, [s. l.], v. 69, n. 2, 2009. Disponível em: <http://dx.doi.org/10.4067/S0718-58392009000200009>

ALOMAR, Daniel; FUCHSLOCHER, Rita; PABLO, Marjorie de. Effect of preparation method on composition and NIR spectra of forage samples. **Animal Feed Science And Technology**, [S.L.], v. 107, n. 1-4, p. 191-200, jun. 2003. Elsevier BV. [http://dx.doi.org/10.1016/s0377-8401\(03\)00124-x](http://dx.doi.org/10.1016/s0377-8401(03)00124-x).

AMORIM, Philipe Lima; LOPES, Erica Laura Guilherme; MOREIRA, Andressa Mirielle; CAVALCANTE, Filipe Souza; LYRA, Guilherme Bastos; ARAÚJO FILHO, José Teodorico; SANTOS, Ana Iris Silva; SOUSA, Braulio Maia Lana. EFEITOS DA INTERCEPTAÇÃO LUMINOSA OU PERÍODO DE DESCANSO FIXO NO ACÚMULO DE FORRAGEM E ESTRUTURA DO DOSSEL DE UMA ANTIGA CULTIVAR DE *Megathyrsus maximus*. **Revista Ciência Agrícola**, [S.L.], v. 18, n. 1, p. 29-37, 12 abr. 2020. Universidade Federal de Alogoaas. <http://dx.doi.org/10.28998/rca.v18i1.8801>.

ANDRÉS, Sonia; MURRAY, Ian; CALLEJA, Alfredo; GIRÁLDEZ, F. Javier. Nutritive Evaluation of Forages by near Infrared Reflectance Spectroscopy. **Journal Of Near Infrared Spectroscopy**, [S.L.], v. 13, n. 6, p. 301-311, dez. 2005. SAGE Publications. <http://dx.doi.org/10.1255/jnirs.561>.

ANDREU-RODRÍGUEZ, J.; PÉREZ-ESPINOSA, A.; PÉREZ-MURCIA, M.D.; MORAL, R.; AGULLÓ, E.; FERRÁNDEZ-VILLENA, M.; FERRÁNDEZ-GARCÍA, M.T.; BUSTAMANTE, M.A.. Near infrared reflectance spectroscopy (NIRS) for the assessment of biomass production and C sequestration by Arundo donax L. in salt-affected environments. **Agricultural Water Management**, [S.L.], v. 183, p. 94-100, mar. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.agwat.2016.10.005>.

ANDUEZA, D.; PICARD, F.; JESTIN, M.; ANDRIEU, J.; BAUMONT, R.. NIRS prediction of the feed value of temperate forages: efficacy of four calibration strategies. **Animal**, [S.L.], v. 5, n. 7, p. 1002-1013, 2011. Elsevier BV. <http://dx.doi.org/10.1017/s1751731110002697>.

ANDUEZA, Donato; PICARD, Fabienne; DOZIAS, Dominique; AUFRÈRE, Jocelyne. Fecal Near-Infrared Reflectance Spectroscopy Prediction of the Feed Value of Temperate Forages for Ruminants and Some Parameters of the Chemical Composition of Feces: efficiency of four calibration strategies. **Applied Spectroscopy**, [S.L.], v. 71, n. 9, p. 2164-2176, 6 jun. 2017. SAGE Publications. <http://dx.doi.org/10.1177/0003702817712740>.

BARBER, G.D.; GIVENS, D.I.; KRIDIS, M.s.; OFFER, N.W.; MURRAY, I.. Prediction of the organic matter digestibility of grass silage. **Animal Feed Science And Technology**, [S.L.], v. 28, n. 1-2, p. 115-128, fev. 1990. Elsevier BV. [http://dx.doi.org/10.1016/0377-8401\(90\)90074-i](http://dx.doi.org/10.1016/0377-8401(90)90074-i).

BARBOSA, Rodrigo Amorim; NASCIMENTO JÚNIOR, Domicio do; EUCLIDES, Valéria Pacheco Batista; SILVA, Sila Carneiro da; ZIMMER, Ademir Hugo; TORRES JÚNIOR, Roberto Augusto de Almeida. Capim-tanzânia submetido a combinações entre intensidade e freqüência de pastejo. **Pesquisa Agropecuária Brasileira**, [S.L.], v. 42, n. 3, p. 329-340, mar. 2007. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0100-204x2007000300005>.

BEć, Krzysztof B; GRABSKA, Justyna; SIESLER, Heinz W; HUCK, Christian W. Handheld near-infrared spectrometers: where are we heading?. **Nir News**, [S.L.], v. 31, n. 3-4, p. 28-35, 13 abr. 2020. SAGE Publications. <http://dx.doi.org/10.1177/0960336020916815>.

BELL, M. J.; MEREU, L.; DAVIS, J. The Use of Mobile Near-Infrared Spectroscopy for Real-Time Pasture Management. **Frontiers in Sustainable Food Systems**, [s. l.], v. 2, 2018. <https://doi.org/10.3389/fsufs.2018.00076>.

BERZAGHI, P.; CHERNEY, J.H.; CASLER, M.D.. Prediction performance of portable near infrared reflectance instruments using preprocessed dried, ground forage samples. **Computers And Electronics In Agriculture**, [S.L.], v. 182, p. 106013, mar. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2021.106013>.

BOEVER, J.L. de; VANACKER, J.M.; BRABANDER, D.L. de. Rumen degradation characteristics of nutrients in compound feeds and the evaluation of tables, laboratory methods and NIRS as predictors. **Animal Feed Science And Technology**, [S.L.], v. 107, n. 1-4, p. 29-43, jun. 2003. Elsevier BV. [http://dx.doi.org/10.1016/s0377-8401\(03\)00063-4](http://dx.doi.org/10.1016/s0377-8401(03)00063-4).

BORREANI, G.; TABACCO, E.; SCHMIDT, R.J.; HOLMES, B.J.; MUCK, R.e.. Silage review: factors affecting dry matter and quality losses in silages. **Journal Of Dairy Science**, [S.L.], v. 101, n. 5, p. 3952-3979, maio 2018. American Dairy Science Association. <http://dx.doi.org/10.3168/jds.2017-13837>.

BRERETON, Richard G.. Introduction to multivariate calibration in analytical chemistry. **The Analyst**, [S.L.], v. 125, n. 11, p. 2125-2154, 2000. Royal Society of Chemistry (RSC). <http://dx.doi.org/10.1039/b003805i>.

BROGNA, N.; PALMONARI, A.; CANESTRARI, G.; MAMMI, L.; PRÀ, A. dal; FORMIGONI, A.. Technical note: near infrared reflectance spectroscopy to predict fecal indigestible neutral detergent fiber for dairy cows. **Journal Of Dairy Science**, [S.L.], v. 101, n. 2, p. 1234-1239, fev. 2018. American Dairy Science Association. <http://dx.doi.org/10.3168/jds.2017-13319>.

BÜNING-PFAUE, Hans. Analysis of water in food by near infrared spectroscopy. **Food Chemistry**, [S.L.], v. 82, n. 1, p. 107-115, jul. 2003. Elsevier BV. [http://dx.doi.org/10.1016/s0308-8146\(02\)00583-6](http://dx.doi.org/10.1016/s0308-8146(02)00583-6).

BURNS, D. A.; CIURCZAK, E. W. (org.). **Handbook of Near-Infrared Analysis**. [S. l.]: CRC Press, 2007. <https://dx.doi.org/10.1201/9781420007374>.

CAMPOS, Ana Carolina Atala Lombelo et al. Levantamento florístico e fitossociológico da mata ciliar do Rio das Mortes em São João del-Rei, Minas Gerais. **Revista Brasileira de Biociências**, v. 5, n. S2, p. 1177-1179, 2007.

CARVALHO, Ana Luiza Silva et al. Production and quality of Mombaça grass forage under different residual heights. **Acta Scientiarum. Animal Sciences**, v. 39, n. 2, p. 143-148, 2017.

CARVALHO, Daniel F. de et al. Coeficientes da equação de Angström-Prescott e sua influência na evapotranspiração de referência em Seropédica, RJ. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 15, p. 838-844, 2011.

CASTRO, P. S. et al. Interceptação da chuva por mata natural secundaria na regiao de Vicoso, MG [Minas Gerais, Brasil]. **Revista árvore**, v. 7, 1983.

CAZETTA, Jairo Osvaldo; VILLELA, Luciana Cristine Vasques. Nitrate reductase activity in leaves and stems of tanner grass (*Brachiaria radicans* Napper). **Scientia Agricola**, [S.L.], v. 61, n. 6, p. 640-648, dez. 2004. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0103-90162004000600012>.

CEN, Haiyan; HE, Yong. Theory and application of near infrared reflectance spectroscopy in determination of food quality. **Trends In Food Science & Technology**, [S.L.], v. 18, n. 2, p. 72-83, fev. 2007. Elsevier BV. <http://dx.doi.org/10.1016/j.tifs.2006.09.003>.

CIENFUGOS, F. Análise instrumental: conceitos e avanços da análise no infravermelho. **Revista Química e Derivados**, São Paulo, v.38, n.413, p.40-46, mar. 2003.

CIURCZAK, E. W. et al. **Handbook of Near-Infrared Analysis**. 4. ed. Fourth edition. | Boca Raton : Taylor and Francis, 2021. |: CRC Press, 2021. <https://dx.doi.org/10.1201/b22513>.

CORSON, D.C.; WAGHORN, G.C.; ULYATT, M.J.; LEE, J.. NIRS: forage analysis and livestock feeding. **Proceedings Of The New Zealand Grassland Association**, [S.L.], p. 127-132, 1 jan. 1999. New Zealand Grassland Association. <http://dx.doi.org/10.33584/jnzg.1999.61.2340>.

COSTA, Ana Beatriz Graciano da; DIFANTE, Gelson dos Santos; GURGEL, Antonio Leandro Chaves; VERAS, Emmanuel Lievio de Lima; RODRIGUES, Jéssica Gomes; PEREIRA, Marislayne de Gusmão; SANTOS, Anna Yanka de Oliveira; EMERENCIANO NETO, João Virgínio; MONTAGNER, Denise Baptaglin. Morphogenic and structural characteristics of *Panicum* cultivars during the establishment period in the Brazilian Northeast. **Acta Scientiarum. Animal Sciences**, [S.L.], v. 43, p. 50984, 19 ago. 2020. Universidade Estadual de Maringá. <http://dx.doi.org/10.4025/actascianimsci.v43i1.50984>.

COZZOLINO, D.; FASSIO, A.; FERNÁNDEZ, E.; RESTAINO, E.; LAMANNA, A.. Measurement of chemical composition in wet whole maize silage by visible and near infrared reflectance spectroscopy. **Animal Feed Science And Technology**, [S.L.], v. 129, n. 3-4, p. 329-336, set. 2006. Elsevier BV. <http://dx.doi.org/10.1016/j.anifeedsci.2006.01.025>.

COZZOLINO, D; A FASSIO,; A GIMENEZ,. The use of near-infrared reflectance spectroscopy (NIRS) to predict the composition of whole maize plants. **Journal Of The Science Of Food And Agriculture**, [S.L.], v. 81, n. 1, p. 142-146, 2001. Wiley. [http://dx.doi.org/10.1002/1097-0010\(20010101\)81:13.0.co;2-i](http://dx.doi.org/10.1002/1097-0010(20010101)81:13.0.co;2-i).

COZZOLINO, D; A MORON,. Exploring the use of near infrared reflectance spectroscopy (NIRS) to predict trace minerals in legumes. **Animal Feed Science And Technology**, [S.L.], v. 111, n. 1-4, p. 161-173, jan. 2004. Elsevier BV. <http://dx.doi.org/10.1016/j.anifeedsci.2003.08.001>.

CROCOMBE, Richard A.. Portable Spectroscopy. **Applied Spectroscopy**, [S.L.], v. 72, n. 12, p. 1701-1751, 18 out. 2018. SAGE Publications. <http://dx.doi.org/10.1177/0003702818809719>.

DALE, Laura M.; THEWIS, André; BOUDRY, Christelle; ROTAR, Ioan; PĂCURAR, Florin S.; ABBAS, Ouissam; DARDELINE, Pierre; BAETEN, Vincent; PFISTER, James; PIERNA, Juan A. Fernández. Discrimination of grassland species and their classification in botanical families by laboratory scale NIR hyperspectral imaging: preliminary results. **Talanta**, [S.L.], v. 116, p. 149-154, nov. 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.talanta.2013.05.006>.

DETMANN, E. *et al.* Métodos para análise de alimentos. 2. ed. Visconde do Rio Branco, MG: Suprema, 2021.

DHANOA, Mewa S.; LÓPEZ, Secundino; SANDERSON, Ruth; LISTER, Sue J.; BARNES, Ralph J.; ELLIS, Jennifer L.; FRANCE, James. Methodology adjusting for least squares regression slope in the application of multiplicative scatter correction to near-infrared spectra of forage feed samples. **Journal Of Chemometrics**, [S.L.], v. 37, n. 11, 3 ago. 2023. Wiley. <http://dx.doi.org/10.1002/cem.3511>.

DIAS, Cristiana Maduro; NUNES, Helder; BORBA, Alfredo. Near-Infrared Spectroscopy Integration in the Regular Monitorization of Pasture Nutritional Properties and Gas Production. **Agriculture**, [S.L.], v. 13, n. 7, p. 1398, 14 jul. 2023. MDPI AG. <http://dx.doi.org/10.3390/agriculture13071398>.

DIAS, Cristiana Maduro; NUNES, Helder; BORBA, Alfredo. Near-Infrared Spectroscopy in Animal Nutrition: historical insights, technical principles, and practical applications. **Analytica**, [S.L.], v. 5, n. 4, p. 481-498, 2 out. 2024. MDPI AG. <http://dx.doi.org/10.3390/analytica5040033>.

EVANGELISTA, Chiara; BASIRICÒ, Loredana; BERNABUCCI, Umberto. An Overview on the Use of Near Infrared Spectroscopy (NIRS) on Farms for the Management of Dairy Cows. **Agriculture**, [S.L.], v. 11, n. 4, p. 296, 30 mar. 2021. MDPI AG. <http://dx.doi.org/10.3390/agriculture11040296>.

FEDORAH, Phillip M.; HRUDEY, Steve E.. A simple apparatus for measuring gas production by methanogenic cultures in serum bottles. **Environmental Technology Letters**, [S.L.], v. 4,

n. 10, p. 425-432, out. 1983. Informa UK Limited.
<http://dx.doi.org/10.1080/09593338309384228>.

FERNANDES, Francisco Duarte; RAMOS, Allan Kardec Braga; JANK, Liana; CARVALHO, Marcelo Ayres; MARTHA JUNIOR, Geraldo Bueno; BRAGA, Gustavo José. Forage yield and nutritive value of *Panicum maximum* genotypes in the Brazilian savannah. **Scientia Agricola**, [S.L.], v. 71, n. 1, p. 23-29, fev. 2014. FapUNIFESP (SciELO).
<http://dx.doi.org/10.1590/s0103-90162014000100003>.

FERRARO, F. P.; NAVE, R. L. G.; SULC, R. M.; BARKER, D. J.. Seasonal Variation in the Rising Plate Meter Calibration for Forage Mass. **Agronomy Journal**, [S.L.], v. 104, n. 1, p. 1-6, jan. 2012. Wiley. <http://dx.doi.org/10.2134/agronj2011.0190>.

FERREIRA, M. M. C. Quimiometria: conceitos, métodos e aplicações. Campinas: **Ed. UNICAMP**, 2016, p. 833. Scielo. <https://dx.doi.org/10.7476/9788526814714>

FOSKOLOS, A.; CALSAMIGLIA, S.; CHRENKOVÁ, M.; WEISBJERG, M.R.; ALBANEZ, E.. Prediction of rumen degradability parameters of a wide range of forages and non-forages by NIRS. **Animal**, [S.L.], v. 9, n. 7, p. 1163-1171, 2015. Elsevier BV.
<http://dx.doi.org/10.1017/s1751731115000191>.

GARCIA, Jaime; COZZOLINO, Daniel. Use of Near Infrared Reflectance (NIR) Spectroscopy to Predict Chemical Composition of Forages in Broad-Based Calibration Models. **Agricultura Técnica**, [S.L.], v. 66, n. 1, p. 41-47, mar. 2006. SciELO Agencia Nacional de Investigacion y Desarrollo (ANID). <http://dx.doi.org/10.4067/s0365-28072006000100005>.

GARNSWORTHY, P. C.; WISEMAN, J.; FEGEROS, K. Prediction of chemical, nutritive and agronomic characteristics of wheat by near infrared spectroscopy. **The Journal of Agricultural Science**, [s. l.], v. 135, n. 4, p. 409-417, 2000. Disponível em: https://www.cambridge.org/core/product/identifier/S0021859699008382/type/journal_article.

GIULIANO TOSTES NOVAIS. **Climas do Brasil: classificação climática e aplicações**. 1. ed. - Porto Alegre: TOTALBOOKS, 2023. Disponível em: https://files.cercomp.ufg.br/weby/up/51/o/Livro_dos_Climas_do_Brasil_-_final.pdf. Acesso em: 12 fev. 2025.

GIVENS, D. I. *et al.* (org.). Forage evaluation in ruminant nutrition. UK: CABI Publishing, 2000. Disponível em: <http://www.cabidigitallibrary.org/doi/book/10.1079/9780851993447.0000>.

GOMIDE, Carlos Augusto de Miranda; GOMIDE, José Alberto. Análise de crescimento de cultivares de *Panicum maximum* Jacq. **Revista Brasileira de Zootecnia**, [S.L.], v. 28, n. 4, p. 675-680, ago. 1999. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1516-35981999000400003>.

HART, Leonie; HUGUENIN-ELIE, Olivier; LATSCH, Roy; SIMMLER, Michael; DUBOIS, Sébastien; UMSTATTER, Christina. Comparison of Spectral Reflectance-Based Smart Farming Tools and a Conventional Approach to Determine Herbage Mass and Grass Quality on Farm. **Remote Sensing**, [S.L.], v. 12, n. 19, p. 3256, 7 out. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12193256>.

HOLTSCHAUSEN, L. *et al.* Feeding saponin-containing *Yucca schidigera* and *Quillaja saponaria* to decrease enteric methane production in dairy cows. **Journal of Dairy Science**, [s. l.], v. 92, n. 6, p. 2809–2821, 2009. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0022030209705983>.

IBÁÑEZ, L.; ALOMAR, D. PREDICTION OF THE CHEMICAL COMPOSITION AND FERMENTATION PARAMETERS OF PASTURE SILAGE BY NEAR INFRARED REFLECTANCE SPECTROSCOPY (NIRS). **CHILEAN JOURNAL OF AGRICULTURAL RESEARCH**, [s. l.], 2009. Disponível em: <https://utoronto.scholaris.ca/items/0979b5ef-e1a4-4a5d-92fc-11ba30d9ecbd>.

IKOYI, A.y.; YOUNGE, B.A.. Influence of forage particle size and residual moisture on near infrared reflectance spectroscopy (NIRS) calibration accuracy for macro-mineral determination. **Animal Feed Science And Technology**, [S.L.], v. 270, p. 114674, dez. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.anifeedsci.2020.114674>.

JHA, S. N.; GARG, Ruchi. Non-destructive prediction of quality of intact apple using near infrared spectroscopy. **Journal Of Food Science And Technology**, [S.L.], v. 47, n. 2, p. 207-213, mar. 2010. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s13197-010-0033-1>.

JOHNSON, K. A.; JOHNSON, D. E.. Methane emissions from cattle. **Journal Of Animal Science**, [S.L.], v. 73, n. 8, p. 2483-2492, 1 ago. 1995. Oxford University Press (OUP). <http://dx.doi.org/10.2527/1995.7382483x>.

KHALSA, J.; FRICKE, T.; WEISSE, W. W.; WEIGELT, A.; WACHENDORF, M.. Effects of functional groups and species richness on biomass constituents relevant for combustion: results from a grassland diversity experiment. **Grass And Forage Science**, [S.L.], v. 67, n. 4, p. 569-588, 12 jul. 2012. Wiley. <http://dx.doi.org/10.1111/j.1365-2494.2012.00884.x>.

KOEHLER; SMALL, Gary W.; COMBS, Roger J.; KNAPP, Robert B.; KROUTIL, Robert T.. Calibration Transfer Algorithm for Automated Qualitative Analysis by Passive Fourier Transform Infrared Spectrometry. **Analytical Chemistry**, [S.L.], v. 72, n. 7, p. 1690-1698, 4 mar. 2000. American Chemical Society (ACS). <http://dx.doi.org/10.1021/ac9907888>.

KRIZSAN, S. J.; HUHTANEN, P. Effect of diet composition and incubation time on feed indigestible neutral detergent fiber concentration in dairy cows. **Journal Of Dairy Science**, [s. l.], v. 96, n. 3, p. 1715–1726, 2013. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0022030213000234>.

KRIZSAN, S.J.; RINNE, M.; NYHOLM, L.; HUHTANEN, P.. New recommendations for the ruminal in situ determination of indigestible neutral detergent fibre. **Animal Feed Science And Technology**, [S.L.], v. 205, p. 31-41, jul. 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.anifeedsci.2015.04.008>.

LABSPHERE. *Spectralon Diffuse Reflectance Standards*. Technical Guide. North Sutton, NH: LabSphere Inc., 2020. Disponível em: <https://www.labsphere.com>. Acesso em: 22 abr. 2025.

LIU, Jinming; ZENG, Changhao; WANG, Na; SHI, Jianfei; ZHANG, Bo; LIU, Changyu; SUN, Yong. Rapid Biochemical Methane Potential Evaluation of Anaerobic Co-Digestion Feedstocks Based on Near Infrared Spectroscopy and Chemometrics. **Energies**, [S.L.], v. 14, n. 5, p. 1460, 7 mar. 2021. MDPI AG. <http://dx.doi.org/10.3390/en14051460>.

LOBOS, I.; MOSCOSO, C. J.; PAVEZ, P. Calibration models for the nutritional quality of fresh pastures by nearinfrared reflectance spectroscopy. **Ciencia E Investigación agraria**, [s. l.], v. 46, n. 3, p. 234–242, 2019. Disponível em: <https://rcia.uc.cl/index.php/ijanr/article/view/2020>.

MACEDO, M. C. M. Pastagens no ecossistema Cerrados: evolução das pesquisas para o desenvolvimento sustentável. In: 2005. **Reunião anual da sociedade brasileira de zootecnia**. [S. l.: s. n.], 2005. p. 56–84. Disponível em: <https://www.researchgate.net/profile/Manuel-Macedo-2/publication/325698028>

MALAVIYA, Devendra Ram; BAIK, Mirza Jaynul; KUMAR, Bijendra; KAUSHAL, Pankaj. Effects of shade on guinea grass genotypes *Megathyrsus maximus* (Poales: poaceae). **Revista de Biología Tropical**, [S.L.], v. 68, n. 2, 17 mar. 2020. Universidad de Costa Rica. <http://dx.doi.org/10.15517/rbt.v68i2.38362>.

MAPBIOMAS BRASIL. [S. l.], [s. d.]. Disponível em: <https://brasil.mapbiomas.org/2024/12/06/pastagem-soja-e-cana-ocupam-77-da-area-de-agropecuaria-no-brasil/>. Acesso em: 12 fev. 2025.

MARTENS, H.; NAES, T. Multivariate calibration. New York: Wiley, 1996.

MOLANO, Martha Lucía; CORTÉS, María Lucía; ÁVILA, Patricia; MARTENS, Siriwan D.; MUÑOZ, Luz Stella. Ecuaciones de calibración en espectroscopía de reflectancia en el infrarrojo cercano (NIRS) para predicción de parámetros nutritivos en forrajes tropicales. **Tropical Grasslands-Forrajes Tropicales**, [S.L.], v. 4, n. 3, p. 139, 2016. Centro Internacional de Agricultura Tropical. [http://dx.doi.org/10.17138/tgft\(4\)139-145](http://dx.doi.org/10.17138/tgft(4)139-145).

MOSCOSO, C. J.; BALOCCHI, O. A.. Concentración de carbohidratos solubles en agua y nitrógeno posterior a la defoliación en ballicas perennes (*Lolium perenne* L.) en primavera. **Agro Sur**, [S.L.], v. 44, n. 3, p. 11-17, 2016. Sistema de Bibliotecas UACH. <http://dx.doi.org/10.4206/agrosur.2016.v44n3-02>.

MOSS, Angela R.; JOUANY, Jean-Pierre; NEWBOLD, John. Methane production by ruminants: its contribution to global warming. In: **Annales de zootechnie**. EDP Sciences, 2000. p. 231-253. Disponível em: <https://hal.science/hal-00889894v1>.

MURRAY, I. The NIR spectra of homologous series of organic compounds. In: **Proceedings of the international NIR/NIT conference**. Akademiai Kiado: Budapest, Hungary, 1986. p. 13-28.

NAES, T., ISAKSSON, T., FEARN, T., DAVIES, T.. A User-Friendly Guide to Multivariate Calibration and Classification. NIR Publications. 2002.

NEUMANN, Mikael; LEÃO, Guilherme Fernando Mattos; SANTOS, Leslei Caroline dos; MARAFON, Fabiano; ASKEL, Eloize Jaqueline. Dupla vedação em silagem de milho na

produção de bovinos confinados. **Revista de Ciências Agroveterinárias**, [S.L.], v. 17, n. 1, p. 100-106, 16 mar. 2015. Universidade do Estado de Santa Catarina. <http://dx.doi.org/10.5965/223811711712018100>.

NGUYEN, Hoang Nam; DEHARENG, Frédéric; HAMMIDA, Mohamed; BAETEN, Vincent; FROIDMONT, Eric; SOYEURT, Hélène; NIEMÖELLER, Andreas; DARDENNE, Pierre. Potential of near Infrared Spectroscopy for On-Line Analysis at the Milking Parlour Using a Fibre-Optic Probe Presentation. **Nir News**, [S.L.], v. 22, n. 7, p. 11-13, nov. 2011. SAGE Publications. <http://dx.doi.org/10.1255/nirn.1271>.

NIU, Kechang; HE, Jin-Sheng; ZHANG, Shiting; LECHOWICZ, Martin J.. Tradeoffs between forage quality and soil fertility: lessons from himalayan rangelands. **Agriculture, Ecosystems & Environment**, [S.L.], v. 234, p. 31-39, out. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.agee.2016.04.023>.

NORMAN, Hayley C.; HULM, Elizabeth; HUMPHRIES, Alan W.; HUGHES, Steve J.; VERCOE, Philip E.. Broad near-infrared spectroscopy calibrations can predict the nutritional value of >100 forage species within the Australian feedbase. **Animal Production Science**, [S.L.], v. 60, n. 8, p. 1111, 2020. CSIRO Publishing. <http://dx.doi.org/10.1071/an19310>.

NORRIS, K. H.; BARNES, R. F.; MOORE, J. E.; SHENK, J. S.. Predicting Forage Quality by Infrared Reflectance Spectroscopy. **Journal Of Animal Science**, [S.L.], v. 43, n. 4, p. 889-897, 1 out. 1976. Oxford University Press (OUP). <http://dx.doi.org/10.2527/jas1976.434889x>.

NUNES, P. G. A. Uma Nova Técnica para Seleção de Variáveis em Calibração Multivariada aplicada as Espectrometrias UV-VIS e NIR. 2008. Tese (Doutorado), Universidade Federal da Paraíba, Paraíba, Brasil.

OLIVEIRA, Denilson Mendes de; PASQUINI, Celio; NOGUEIRA, Ana Rita de Araújo; RABELO, Márcio Dias; SIMEONE, Maria Lúcia Ferreira; SOUZA, Gilberto Batista de. Comparative analysis of compact and benchtop near-infrared spectrometers for forage nutritional trait measurements. **Microchemical Journal**, [S.L.], v. 196, p. 109682, jan. 2024. Elsevier BV. <http://dx.doi.org/10.1016/j.microc.2023.109682>.

OLIVEIRA, Elson Marcos de; MARTUSCELLO, Janaina Azevedo; JANK, Liana; CUNHA, Daniel de Noronha Figueiredo Vieira da; SANTOS, Mateus Figueiredo. Evaluation of *Megathyrsus maximus* genotypes under water stress conditions. **Acta Scientiarum. Animal Sciences**, [S.L.], v. 44, p. 54975, 10 maio 2022. Universidade Estadual de Maringá. <http://dx.doi.org/10.4025/actascianimsci.v44i1.54975>.

OSBORNE, Brian G.; DOUGLAS, Stuart. Measurement of the degree of starch damage in flour by near infrared reflectance analysis. **Journal Of The Science Of Food And Agriculture**, [S.L.], v. 32, n. 4, p. 328-332, abr. 1981. Wiley. <http://dx.doi.org/10.1002/jsfa.2740320403>.

PARK, R.S; AGNEW, R.E; GORDON, F.J; STEEN, R.W.J. The use of near infrared reflectance spectroscopy (NIRS) on undried samples of grass silage to predict chemical composition and digestibility parameters. **Animal Feed Science And Technology**, [S.L.], v. 72, n. 1-2, p. 155-167, maio 1998. Elsevier BV. [http://dx.doi.org/10.1016/s0377-8401\(97\)00175-2](http://dx.doi.org/10.1016/s0377-8401(97)00175-2).

PARRINI, Silvia; ACCIAIOLI, Anna; CROVETTI, Alessandro; BOZZI, Riccardo. Use of FT-NIRS for determination of chemical components and nutritional value of natural pasture. **Italian Journal Of Animal Science**, [S.L.], v. 17, n. 1, p. 87-91, 7 jul. 2017. Informa UK Limited. <http://dx.doi.org/10.1080/1828051x.2017.1345659>.

PARRINI, Silvia; ACCIAIOLI, Anna; FRANCI, Oreste; PUGLIESE, Carolina; BOZZI, Riccardo. Near Infrared Spectroscopy technology for prediction of chemical composition of natural fresh pastures. **Journal Of Applied Animal Research**, [S.L.], v. 47, n. 1, p. 514-520, 1 jan. 2019. Informa UK Limited. <http://dx.doi.org/10.1080/09712119.2019.1675669>.

PASQUINI, Celio. Near infrared spectroscopy: a mature analytical technique with new perspectives :: a review. **Analytica Chimica Acta**, [S.L.], v. 1026, p. 8-36, out. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.aca.2018.04.004>.

PASQUINI, Celio. Near Infrared Spectroscopy: fundamentals, practical aspects and analytical applications. **Journal Of The Brazilian Chemical Society**, [S.L.], v. 14, n. 2, p. 198-219, abr. 2003. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0103-50532003000200006>.

PAUL, C. Effect of soil contamination on NIRS analysis of grass silage. **Analytical Application Of Spectroscopy**, p. 84-90, 1990.

PEREIRA, Mariana; ALMEIDA, Roberto Giolo de; MACEDO, Manuel Claudio Motta; SANTOS, Valéria Ana Corvalã dos; GAMARRA, Erick Lemes; CASTRO-MONTOYA, Joaquín; LEMPP, Beatriz; MORAIS, Maria da Graça. Anatomical and nutritional characteristics of *Megathyrsus maximus* genotypes under a silvopastoral system. **Tropical Grasslands-Forrajes Tropicales**, [S.L.], v. 9, n. 2, p. 159-170, 31 maio 2021. Centro Internacional de Agricultura Tropical. [http://dx.doi.org/10.17138/tgft\(9\)159-170](http://dx.doi.org/10.17138/tgft(9)159-170).

PIMENTEL, Maria Fernanda; NETO, B. Barros. Calibração: uma revisão para químicos analíticos. **Química Nova**, v. 19, n. 3, p. 268-277, 1996.

PINO, F.H.; HEINRICHS, A.J.. Comparison of on-farm forage-dry-matter methods to forced-air oven for determining forage dry matter. **The Professional Animal Scientist**, [S.L.], v. 30, n. 1, p. 33-36, fev. 2014. American Registry of Professional Animal Scientists. [http://dx.doi.org/10.15232/s1080-7446\(15\)30079-6](http://dx.doi.org/10.15232/s1080-7446(15)30079-6).

PUJOL, S.; PÉREZ-VENDRELL, A.M.; TORRALLARDONA, D.. Evaluation of prediction of barley digestible nutrient content with near-infrared reflectance spectroscopy (NIRS). **Livestock Science**, [S.L.], v. 109, n. 1-3, p. 189-192, maio 2007. Elsevier BV. <http://dx.doi.org/10.1016/j.livsci.2007.01.144>.

QUEIROZ FILHO, José Leite de; SILVA, Divan Soares da; NASCIMENTO, Inalde Soares do. Produção de matéria seca e qualidade do capim-elefante (*Pennisetum purpureum* Schum.) cultivar Roxo em diferentes idades de corte. **Revista Brasileira de Zootecnia**, [S.L.], v. 29, n. 1, p. 69-74, fev. 2000. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1516-35982000000100010>.

REDDERSEN, Björn; FRICKE, Thomas; WACHENDORF, Michael. Effects of sample preparation and measurement standardization on the NIRS calibration quality of nitrogen, ash and NDFom content in extensive experimental grassland biomass. **Animal Feed Science And**

Technology, [S.L.], v. 183, n. 3-4, p. 77-85, jul. 2013. Elsevier BV.
<http://dx.doi.org/10.1016/j.anifeedsci.2013.04.016>.

REGO, Guillermo; FERRERO, Francisco; VALLEDOR, Marta; CAMPO, Juan Carlos; FORCADA, Sergio; ROYO, Luis J.; SOLDADO, Ana. A portable IoT NIR spectroscopic system to analyze the quality of dairy farm forage. **Computers And Electronics In Agriculture**, [S.L.], v. 175, p. 105578, ago. 2020. Elsevier BV.
<http://dx.doi.org/10.1016/j.compag.2020.105578>.

REICH, G. Near-infrared spectroscopy and imaging: basic principles and pharmaceutical applications. **Advanced Drug Delivery Reviews**, [S.L.], v. 57, n. 8, p. 1109-1143, 15 jun. 2005. Elsevier BV. <http://dx.doi.org/10.1016/j.addr.2005.01.020>.

RODRIGUES, Marcônio Martins; OLIVEIRA, Maria Elizabete; LEAL, Tânia Maria; MOURA, Raniel Lustosa; ARAÚJO, Daniel Louçana da Costa; SANTOS, Maurílio Sousa dos; RODRIGUES, Francelino Neiva; RODRIGUES, Viviany Sousa. Forage intake processes by goats on a massai grass pasture with different sward heights. **Semina: Ciências Agrárias**, [S.L.], v. 37, n. 6, p. 4339, 14 dez. 2016. Universidade Estadual de Londrina.
<http://dx.doi.org/10.5433/1679-0359.2016v37n6p4339>.

SANTANA, Felipe B. de; GIUSEPPE, Larissa O. de; SOUZA, André M. de; POPPI, Ronei J.. Removing the moisture effect in soil organic matter determination using NIR spectroscopy and PLSR with external parameter orthogonalization. **Microchemical Journal**, [S.L.], v. 145, p. 1094-1101, mar. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.microc.2018.12.027>.

SENA, M. M. *et al.* **Multivariate Statistical Analysis and Chemometrics**. 1. ed. Boca Raton, FL : CRC Press, Taylor & Francis Group, 2017.: CRC Press, 2017. Disponível em: <https://www.taylorfrancis.com/books/9781498754644>.

SERGIO DE ZEN, P. *et al.* Ano 10-38^a Edição-Fevereiro de. [s. l.], 2018. Disponível em: Acesso em: 17 fev. 2025.

SHI, Ji-Yong; ZOU, Xiao-Bo; ZHAO, Jie-Wen; MEL, Holmes; WANG, Kai-Liang; WANG, Xue; CHEN, Hong. Determination of total flavonoids content in fresh Ginkgo biloba leaf with different colors using near infrared spectroscopy. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, [S.L.], v. 94, p. 271-276, ago. 2012. Elsevier BV.
<http://dx.doi.org/10.1016/j.saa.2012.03.078>.

SIESLER, Heinz W. *et al.* (Ed.). **Near-infrared spectroscopy: principles, instruments, applications**. John Wiley & Sons, 2008.

SILVA, Fabiano Ferreira da; SÁ, Jacqueline Firmino de; SCHIO, Alex Resende; ÍTAVO, Luís Carlos Víñhas; SILVA, Robério Rodrigues; MATEUS, Rodrigo Gonçalves. Suplementação a pasto: disponibilidade e qualidade x níveis de suplementação x desempenho. **Revista Brasileira de Zootecnia**, [S.L.], v. 38, n. , p. 371-389, jul. 2009. FapUNIFESP (SciELO).
<http://dx.doi.org/10.1590/s1516-35982009001300037>.

SOTELO, F.F. Aplicações da espectroscopia de infravermelho próximo na caracterização de petróleo. Simulação de uma unidade de destilação atmosférica. 2006. 154 p. Tese (Doutorado em Engenharia Química) – Universidade de São Paulo, São Paulo.

SOUZA, André Marcelo de; POPPI, Ronei Jesus. Experimento didático de quimiometria para análise exploratória de óleos vegetais comestíveis por espectroscopia no infravermelho médio e análise de componentes principais: um tutorial, parte i. **Química Nova**, [S.L.], v. 35, n. 1, p. 223-229, 2012. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0100-40422012000100039>.

SU, Huawei; SHA, Kun; ZHANG, Li; ZHANG, Qian; XU, Yuling; ZHANG, Rong; LI, Haipeng; SUN, Baozhong. Development of near infrared reflectance spectroscopy to predict chemical composition with a wide range of variability in beef. **Meat Science**, [S.L.], v. 98, n. 2, p. 110-114, out. 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.meatsci.2013.12.019>.

TASSONE, S.; MASOERO, G.; PEIRETTI, P.G.. Vibrational spectroscopy to predict in vitro digestibility and the maturity index of different forage crops during the growing cycle and after freeze- or oven-drying treatment. **Animal Feed Science And Technology**, [S.L.], v. 194, p. 12-25, ago. 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.anifeedsci.2014.04.019>.

THEODOROU, Michael K.; WILLIAMS, Barbara A.; DHANOA, Mewa S.; MCALLAN, Alex B.; FRANCE, James. A simple gas production method using a pressure transducer to determine the fermentation kinetics of ruminant feeds. **Animal Feed Science And Technology**, [S.L.], v. 48, n. 3-4, p. 185-197, ago. 1994. Elsevier BV. [http://dx.doi.org/10.1016/0377-8401\(94\)90171-6](http://dx.doi.org/10.1016/0377-8401(94)90171-6).

TIAN, Wenfei; CHEN, Gengjun; ZHANG, Guorong; WANG, Donghai; TILLEY, Michael; LI, Yonghui. Rapid determination of total phenolic content of whole wheat flour using near-infrared spectroscopy and chemometrics. **Food Chemistry**, [S.L.], v. 344, p. 128633, maio 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.foodchem.2020.128633>.

TIBOLA, Casiane Salete et al. Espectroscopia no infravermelho próximo para avaliar indicadores de qualidade tecnológica e contaminantes em grãos. **Brasília: Embrapa**, 2018.

TORNIAINEN, Jari; AFARA, Isaac O.; PRAKASH, Mithilesh; SARIN, Jaakko K.; STENROTH, Lauri; TÖYRÄS, Juha. Open-source python module for automated preprocessing of near infrared spectroscopic data. **Analytica Chimica Acta**, [S.L.], v. 1108, p. 1-9, abr. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.aca.2020.02.030>.

TRAN, H.; SALGADO, P.; TILLARD, E.; DARDENNE, P.; NGUYEN, X.T.; LECOMTE, P.. “Global” and “local” predictions of dairy diet nutritional quality using near infrared reflectance spectroscopy. **Journal Of Dairy Science**, [S.L.], v. 93, n. 10, p. 4961-4975, out. 2010. American Dairy Science Association. <http://dx.doi.org/10.3168/jds.2008-1893>.

UNGERFELD, Emilio M.. Metabolic Hydrogen Flows in Rumen Fermentation: principles and possibilities of interventions. **Frontiers In Microbiology**, [S.L.], v. 11, p. 589, 15 abr. 2020. Frontiers Media SA. <http://dx.doi.org/10.3389/fmicb.2020.00589>.

URBANO, Stela Antas; RODRIGUES, Jessica Caroline Nascimento; RIBEIRO, Pedro Henrique Cavalcante; SILVA, Yasmin dos Santos; SILVA, Rodrigo Ferreira da; EMERENCIANO NETO, João Virgílio; RANGEL, Adriano Henrique do Nascimento; OLIVEIRA, Juliana Paula Felipe de; MEDEIROS, Henrique Rocha de. Nutrient Intake, Performance, Carcass Characteristics, Meat Quality, and Cost Analysis of Sheep Submitted to

Intermittent Supplementation on Masai Grass Pastures. **Animals**, [S.L.], v. 13, n. 7, p. 1267, 6 abr. 2023. MDPI AG. <http://dx.doi.org/10.3390/ani13071267>.

VARMUZA, K.; FILZMOSER, P. **Introduction to Multivariate Statistical Analysis in Chemometrics**. 1. ed. [S. l.]: CRC Press, 2016. Disponível em: <https://www.taylorfrancis.com/books/9781420059496>.

VON JACQUIN, Nikolaus Joseph; VON JACQUIN, Nikolaus Joseph Freiherr. **Icones plantarum rariorū**. apud CF Wappler, 1781.

VRANIĆ, Marina; BOŁNJAK, Krešimir; RUKAVINA, Ivana; GLAVANOVIĆ, Siniša; PUKEC, Nataša Pintić; BABIĆ, Andreja; VRANIĆ, Ivica. Prediction of forage chemical composition by NIR spectroscopy. **Journal Of Central European Agriculture**, [S.L.], v. 21, n. 3, p. 554-568, 2020. Journal of Central European Agriculture. <http://dx.doi.org/10.5513/jcea01/21.3.2839>.

WITTKOP, Benjamin; SNOWDON, Rod J.; FRIEDT, Wolfgang. New NIRS Calibrations for Fiber Fractions Reveal Broad Genetic Variation in *Brassica napus* Seed Quality. **Journal Of Agricultural And Food Chemistry**, [S.L.], v. 60, n. 9, p. 2248-2256, 21 fev. 2012. American Chemical Society (ACS). <http://dx.doi.org/10.1021/jf204936f>.

YAN, Hui; SIESLER, Heinz W. Hand-held near-infrared spectrometers: state-of-the-art instrumentation and practical applications. **Nir News**, [S.L.], v. 29, n. 7, p. 8-12, 20 ago. 2018. SAGE Publications. <http://dx.doi.org/10.1177/0960336018796391>.

ZHANG, Baohua; GU, Baoxing; TIAN, Guangzhao; ZHOU, Jun; HUANG, Jichao; XIONG, Yingjun. Challenges and solutions of optical-based nondestructive quality inspection for robotic fruit and vegetable grading systems: a technical review. **Trends In Food Science & Technology**, [S.L.], v. 81, p. 213-231, nov. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.tifs.2018.09.018>.

ZHANG, Wenwen; KASUN, Liyanaarachchi Chamara; WANG, Qi Jie; ZHENG, Yuanjin; LIN, Zhiping. A Review of Machine Learning for Near-Infrared Spectroscopy. **Sensors**, [S.L.], v. 22, n. 24, p. 9764, 13 dez. 2022. MDPI AG. <http://dx.doi.org/10.3390/s22249764>.