

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

DISSERTAÇÃO

**Processamento Físico de Amostras de *Urochloa* spp. e Seus Efeitos na
Predição do Valor Nutritivo por Espectroscopia de Infravermelho Próximo
Portátil**

Ariel Thais Rodrigues Alves

2025



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

**PROCESSAMENTO FÍSICO DE AMOSTRAS DE *Urochloa* spp. E SEUS
EFEITOS NA PREDIÇÃO DO VALOR NUTRITIVO POR
ESPECTROSCOPIA DE INFRAVERMELHO PRÓXIMO PORTÁTIL**

Ariel Thais Rodrigues Alves

Sob a Orientação do Professor
João Paulo Pacheco Rodrigues

Co-orientação da Professora
Luana Marta de Almeida Rufino
e Co-orientação do Professor
Carlos Augusto Brandão de Carvalho

Dissertação submetida como requisito
parcial para obtenção do grau de **Mestre**,
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)

A474p

Alves, Ariel Thais Rodrigues, 1998-
Processamento físico de amostras de Urochloa spp. e
seus efeitos na predição do valor nutritivo por
espectroscopia de infravermelho próximo portátil /
Ariel Thais Rodrigues Alves. - Seropédica, 2025.
43 f.: il.

Orientador: João Paulo Pacheco Rodrigues.
Coorientadora: Luana Marta de Almeida Rufino.
Coorientador: Carlos Augusto Brandão de Carvalho.
Dissertação(Mestrado). -- Universidade Federal
Rural do Rio de Janeiro, Programa de Pós-Graduação em
Ciência Animal, 2025.

1. Características nutricionais de forragens. 2.
Gramíneas tropicais. 3. NIRS. I. Rodrigues, João Paulo
Pacheco, 1988-, orient. II. Rufino, Luana Marta de
Almeida, 1987-, coorient. III. Carvalho, Carlos
Augusto Brandão de, 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

ARIEL THAIS RODRIGUES ALVES

Dissertação 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, APROVADA EM 27/02/2025

Documento assinado digitalmente
 JOAO PAULO PACHECO RODRIGUES
Data: 13/11/2025 10:10:14-0300
Verifique em <https://validar.iti.gov.br>

Assinatura

João Paulo Pacheco Rodrigues. Dr. UFRRJ
(Orientador)

Documento assinado digitalmente
 MIRTON JOSE FROTA MORENZ
Data: 14/11/2025 10:19:19-0300
Verifique em <https://validar.iti.gov.br>

Assinatura

Mirton José Frota Morenz. Dr. Embrapa Gado de Leite

Documento assinado digitalmente
 JULIAN ANDRES CASTILLO VARGAS
Data: 17/11/2025 09:02:22-0300
Verifique em <https://validar.iti.gov.br>

Assinatura

Julián Andrés Castillo Vargas. Dr. UVA

AGRADECIMENTOS

À minha mãe, por todo o apoio e incentivo, por não me deixar desistir, por tornar possível que eu chegasse até aqui, por trabalhar dia e noite para que meu sonho se concretizasse.

À Priscila, que encarou essa etapa sempre ao meu lado, me apoiando, dando força e suporte em todos os momentos, bons ou ruins. Ao Hugo e Márcio, amigos de campo, laboratório e vida, que me acompanharam e auxiliaram nessa jornada, tornando possível a realização desse projeto. Com vocês, se tornou mais leve.

À equipe RUMINALAB, em especial Crysthal, Stella, Letícia, Jonathan e Mariana, por todo o auxílio e suporte na execução do experimento. Sem vocês, não teria sido possível.

À Lorraine, por toda dedicação, suporte e zelo para com este projeto, sempre disposta a ajudar.

À minha amiga e companheira de casa, Ana, e aos meus demais amigos, por me proporcionarem todo o suporte emocional necessário para que eu conseguisse chegar até o fim.

Ao meu querido orientador João Paulo, por toda confiança, paciência e pela oportunidade. Sua orientação, sempre cuidadosa e dedicada, foi essencial para o meu crescimento acadêmico e pessoal. Sou imensamente grata por todo o aprendizado compartilhado.

À minha coorientadora Luana Rufino, por todo conhecimento compartilhado, pela sua humanidade e conselhos.

Ao meu coorientador Carlos Augusto, pelo excelente profissional que tive a oportunidade de conhecer.

Ao professor Adenilson Paiva, por sempre estar disponível para compartilhar seus conhecimentos e não medir esforços para ajudar quando necessário.

À EMBRAPA Gado de Leite, UFLA e UFV pelo auxílio à execução do experimento.

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.

E, por fim, à UFRRJ e ao PGCA, pela oportunidade de poder usufruir de um ensino gratuito e de qualidade.

RESUMO

ALVES, Ariel Thais Rodrigues. **Processamento físico de amostras de *Urochloa* spp. e seus efeitos na predição do valor nutritivo por espectroscopia de infravermelho próximo portátil.** 2025. 43p 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) é uma ferramenta promissora para avaliar a qualidade de forragens de forma rápida e não destrutiva, embora seu desempenho possa variar conforme o processamento físico das amostras e o equipamento utilizado. Nesse contexto, o presente estudo teve como objetivo avaliar os efeitos do processamento físico de amostras de *Urochloa* spp. sobre a predição do valor nutritivo por NIRS portátil (NIRSp) de baixo custo. Foram analisadas 121 amostras de *Urochloa* spp., submetidas a quatro graus de processamento físico: amostras frescas (FR), secas (SC), secas e moídas a 2 mm (SM2) e secas e moídas a 1 mm (SM1). As amostras foram coletadas a 50% da altura do dossel, picadas, homogeneizadas e submetidas aos diferentes graus de processamento, com seis espectros aleatórios obtidos para cada processamento utilizando um NIRSp (900–1700 nm; MyNIR, *Spectral Solutions*, São Paulo, Brasil). Os espectros obtidos foram relacionados a parâmetros bromatológicos, de digestibilidade e produção de gás: matéria seca (MS), matéria orgânica (MO), nitrogênio (N), fibra em detergente neutro (FDN), FDN corrigida para cinzas (FDNc), FDN indigestível (FDNi), digestibilidade *in vitro* da MS (DIVMS), digestibilidade *in vitro* da FDN (DIVFDN) e rendimento de metano *in vitro* (*in vitro*-CH₄). Foram testadas 100 abordagens espectrais e os modelos foram calibrados por regressão por mínimos quadrados parciais (PLSR), com validação cruzada *leave-one-out* (LOOCV), e seu desempenho avaliado por coeficiente de determinação da LOOCV (R^2 test), coeficiente de determinação da calibração (R^2 train), erro quadrático médio da predição (RMSEP), raiz do erro quadrático médio de predição em % do valor médio observado (RMSEP%), inclinação da reta (*slope*), intercepto entre valores preditos e observados e erro absoluto médio (MAE). Os resultados demonstraram que o grau de processamento físico influenciou significativamente a qualidade preditiva dos modelos. As amostras FR mostraram menor precisão geral, mas desempenho viável para MS (R^2 test = 0,82; RMSEP = 2,37), FDNi (R^2 test = 0,72; RMSEP = 2,03) e N (R^2 test = 0,55; RMSEP = 0,31; *slope* = 0,85; MAE = 0,0045). As amostras SC mantiveram alinhamento em MS (R^2 test = 0,80; RMSEP = 2,36) e FDNi (R^2 test = 0,78; RMSEP = 1,73). As amostras SM2 tiveram R^2 test 0,59 e 0,86 e RMSEP% 0,85 e 9,43 para MO e N, com alinhamento adequado, mas interceptos mais altos que SM1. As amostras SM1 apresentaram os maiores R^2 test para MS (0,84), FDN (0,87), FDNc (0,86), FDNi (0,79), DIVMS (0,74) e DIVFDN (0,76), com RMSEP% até 11,48 e *slopes* próximos de 1. Por outro lado, *in vitro*-CH₄ foi limitada em todos os graus de processamento (R^2 test $\leq$ 0,39), com alta variabilidade e acurácia reduzida. Conclui-se que o NIRSp é uma alternativa eficaz e acessível para predição nutricional, especialmente quando associado ao preparo adequado das amostras, com potencial de aplicação direta em campo com uso de material fresco.

Palavras-chave: características nutricionais de forragens, gramíneas tropicais, NIRS

ABSTRACT

ALVES, Ariel Thais Rodrigues. **Physical processing of *Urochloa* spp. samples and its effects on the prediction of nutritional value by handheld near-infrared spectroscopy.** 2025. 43p
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) is a promising tool for rapidly and non-destructively assessing forage quality, although its performance may vary depending on the physical processing of samples and the equipment used. In this context, the present study aimed to evaluate the effects of physical processing of *Urochloa* spp. samples on the prediction of nutritional value using a low-cost portable NIRS device (pNIRS). A total of 121 *Urochloa* spp. samples were analyzed under four levels of physical processing: fresh samples (FR), dried (DR), dried and ground to 2 mm (DG2), and dried and ground to 1 mm (DG1). Samples were collected at 50% of canopy height, chopped, homogenized, and processed accordingly. Six random spectral readings were obtained per processing level using a pNIRS device (900–1700 nm; MyNIR, Spectral Solutions, São Paulo, Brazil). Spectra were related to bromatological, digestibility, and gas production parameters: dry matter (DM), organic matter (OM), nitrogen (N), neutral detergent fiber (NDF), ash-free NDF (NDFom), indigestible NDF (iNDF), in vitro digestibility of DM (IVDMD), in vitro digestibility of NDF (IVNDF), and in vitro methane yield (in vitro-CH₄). One hundred spectral preprocessing approaches were tested, and models were calibrated using partial least squares regression (PLSR) with leave-one-out cross-validation (LOOCV). Model performance was assessed through R² test, R² train, root mean square error of prediction (RMSEP), RMSEP%, slope, intercept, and mean absolute error (MAE). The FR samples showed lower overall precision but viable performance for DM (R² test = 0.82; RMSEP = 2.37), iNDF (R² test = 0.72; RMSEP = 2.03), and N (R² test = 0.55; RMSEP = 0.31; slope = 0.85; MAE = 0.0045). The DR samples maintained alignment for DM (R² test = 0.80; RMSEP = 2.36) and iNDF (R² test = 0.78; RMSEP = 1.73). The DG2 samples showed R² test values of 0.59 and 0.86 and RMSEP% of 0.85 and 9.43 for OM and N, respectively, with adequate alignment but higher intercepts compared to DG1. The DG1 samples presented the highest R² test values for DM (0.84), NDF (0.87), NDFom (0.86), iNDF (0.79), IVDMD (0.74), and IVNDF (0.76), with RMSEP% up to 11.48 and slopes close to 1. In contrast, in vitro-CH₄ showed limited predictive capacity across all processing levels (R² test ≤ 0.39), with high variability and reduced accuracy. It is concluded that pNIRS is an effective and affordable alternative for nutritional prediction, particularly when combined with appropriate sample preparation, and holds practical potential for direct field application using fresh material.

Keywords: forage nutritional traits, NIRS, tropical grasses

LISTA DE TABELAS

Tabela 1. Quantitativo de espécies e cultivares coletadas do gênero *Urochloa*.

Tabela 2. Valores de média, mínimo, máximo e desvio padrão da altura, composição bromatológica via úmida, digestibilidade e rendimento de metano *in vitro* (% da matéria seca, salvo indicação).

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

LISTA DE FIGURAS

Figura 1. Coleta das amostragens espectrais nos 4 graus de processamento de amostra: (A) fresca; (B) seca; (C) seca e moída a 2 mm; (D) seca e moída a 1 mm.

Figura 2. Fluxograma das etapas de processamento físico das amostras de *Urochloa* spp., aquisição espectral, calibração e análises laboratoriais. As amostras foram avaliadas nos estados fresca, seca, seca e moída a 2 mm e seca e moída a 1 mm, com seis amostragens espectrais realizadas para cada condição. O modelo de calibração foi construído utilizando validação cruzada *leave-one-out* (LOOCV) e avaliado por métricas de desempenho, incluindo raiz do erro quadrático médio (RMSEP), raiz do erro quadrático médio de predição em % do valor médio observado (RMSEP%), coeficiente de determinação da validação (R^2 *test*), coeficiente de determinação da calibração (R^2 *train*), inclinação da reta (*Slope*), intercepto e erro médio absoluto (MAE). As análises laboratoriais determinaram o teor de matéria seca (MS), matéria orgânica (MO), nitrogênio (N), fibra insolúvel em detergente neutro (FDN), FDN corrigida para cinzas (FDNc), FDN indigestível (FDNi), digestibilidade *in vitro* da MS (DIVMS), digestibilidade *in vitro* da FDN (DIVFDN) e rendimento de metano *in vitro* (*in vitro*-CH₄).

Figura 3. Espectros brutos individuais de 121 amostras de *Urochloa* spp. submetidas a diferentes graus de processamento físico: amostra fresca, amostra seca, amostra seca e moída a 2 mm (2 mm) e amostra seca e moída a 1 mm (1 mm). As absorvâncias foram obtidas no intervalo de 900 a 1700 nm utilizando espectroscopia no infravermelho próximo portátil.

Figura 4. Médias dos espectros brutos de 121 amostras de *Urochloa* spp. submetidas a diferentes graus de processamento físico: amostra fresca, amostra seca, amostra seca e moída a 2 mm (2 mm) e amostra seca e moída a 1 mm (1 mm). As medidas de absorvância foram obtidas no intervalo de 900 a 1700 nm utilizando espectroscopia no infravermelho próximo portátil.

Figura 5. Regressão linear entre valores preditos e observados para MS em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.

Figura 6. Regressão linear entre valores preditos e observados para MO em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.

Figura 7. Regressão linear entre valores preditos e observados para N em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.

Figura 8. Regressão linear entre valores preditos e observados para FDN em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.

Figura 9. Regressão linear entre valores preditos e observados para FDNc em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha

tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.

Figura 10. Regressão linear entre valores preditos e observados para FDNi em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.

Figura 11. Regressão linear entre valores preditos e observados para DIVMS em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.

Figura 12. Regressão linear entre valores preditos e observados para DIVFDN em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.

Figura 13. Regressão linear entre valores preditos e observados para *in vitro*-CH₄ em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.

SUMÁRIO

1 INTRODUÇÃO.....	1
2 REVISÃO DE LITERATURA.....	3
2.1 Importância das Pastagens e Produção Animal.....	3
2.2 Gramíneas <i>Urochloa</i> spp.....	3
2.3 Espectroscopia de Infravermelho Próximo.....	4
2.4 Desenvolvimento de Modelos Preditivos na NIRS.....	4
2.5 Processamento Físico das Amostras e Aplicação de Equipamentos NIRS Portáteis.....	5
3 MATERIAL E MÉTODOS.....	7
3.1 Local e Quantitativo de Amostras.....	7
3.2 Coletas e Amostragem.....	8
3.3 Análises Laboratoriais.....	9
3.4 Análises Estatísticas.....	10
4 RESULTADOS.....	13
4.1 Caracterização das Amostras.....	13
4.2 Análise dos Espectros Brutos.....	13
4.3 Desempenho dos Modelos de Calibração.....	15
5 DISCUSSÃO.....	26
6 CONCLUSÕES.....	29
7 REFERÊNCIAS BIBLIOGRÁFICAS.....	30

1 INTRODUÇÃO

A produção de ruminantes em pastejo desempenha um papel crucial no contexto global, principalmente pela utilização de territórios para a produção de alimentos como carne, leite e outros produtos (Sahlin et al., 2024). Em ambientes tropicais, a base desses sistemas é composta por gramíneas forrageiras, entre as quais as espécies do gênero *Urochloa* (syn. *Brachiaria*) se destacam. Essas forragens apresentam consideráveis variações em sua composição química e digestibilidade, influenciadas por fatores edafoclimáticos e práticas de manejo (Silva et al., 2021; Soares et al., 2009). Conhecer com precisão a qualidade dessas pastagens é essencial para o balanceamento das dietas, porém o monitoramento em tempo real ainda é limitado, devido à morosidade e ao custo dos métodos laboratoriais convencionais que envolve processos de amostragem, processamento, preparo de amostras e análises lentas, complexas e muitas vezes inviáveis.

Dessa forma, a espectroscopia de infravermelho próximo (NIRS) tem sido utilizada na predição da composição química de forragens, principalmente com amostras secas e moídas analisadas em espectrofotômetros de bancada, onde há maior estabilidade nos modelos e menor interferência da umidade (Berzaghi; Cherney; Casler, 2021; Murphy et al., 2022; Oliveira et al., 2024; Yang et al., 2024). Em comparação aos métodos laboratoriais convencionais, a NIRS, quando devidamente calibrada, destaca-se pela rapidez, menor custo, capacidade de quantificar múltiplos parâmetros simultaneamente, ausência de reagentes químicos, necessidade mínima de preparo das amostras e facilidade de uso (Minet et al., 2021).

Nesse contexto, os espectrofotômetros portáteis surgem como alternativa viável e promissora para análises rápidas e em tempo real, diretamente no campo. Apesar de apresentarem menor sensibilidade analítica em comparação aos modelos de bancada, esses equipamentos têm demonstrado bom desempenho preditivo e oferecem vantagens operacionais importantes, como menor custo, portabilidade e praticidade (Oliveira et al., 2024). Contudo, seu uso ainda demanda estudos adicionais, uma vez que fatores como faixa espectral, intensidade da fonte de luz, método de captação da absorbância e variações na forma física das amostras podem impactar a qualidade dos espectros e exigem calibrações robustas para diferentes condições (Béc et al., 2020; Cherney; Digman; Cherney, 2021; Yamada et al., 2024). Ainda assim, o aparelho NIRS portátil (NIRSp) representa uma ferramenta valiosa para o avanço da nutrição de ruminantes em sistemas produtivos dinâmicos e desafiadores, como os de pastagens tropicais.

Apesar da crescente aplicação da NIRS em forragens tropicais, há uma escassez de estudos que considerem o efeito do preparo físico das amostras sobre o desempenho dos modelos preditivos, especialmente em gramíneas do gênero *Urochloa*. Considerando que fatores como umidade, homogeneidade e granulometria influenciam a interação da radiação com a matriz vegetal, torna-se fundamental compreender como diferentes graus de processamento, de amostras frescas a secas e moídas em diferentes granulometrias, afetam a qualidade espectral e a acurácia das estimativas nutricionais. Diante desse cenário, levanta-se a hipótese de que o grau de processamento físico das amostras de *Urochloa* spp. influencia significativamente a qualidade dos espectros obtidos por NIRSp, afetando a acurácia e robustez dos modelos preditivos de valor nutritivo. Assim, o objetivo deste trabalho é avaliar os efeitos de diferentes graus de processamento físico de amostras de *Urochloa* spp. (fresca, seca, seca e

moída a 2 mm, e seca e moída a 1 mm) sobre a predição do valor nutritivo utilizando NIRSp de baixo custo e modelagem quimiométrica.

2 REVISÃO DE LITERATURA

2.1 Importância das Pastagens e Produção Animal

As pastagens desempenham um papel fundamental na economia das propriedades rurais em diversas regiões do mundo, ocupando aproximadamente 26% da área total mundial e 80% das terras disponíveis para a atividade agrícola, pois representam uma fonte de alimento acessível para ruminantes, permitindo o uso eficiente das áreas disponíveis para a produção animal (Cardoso et al., 2020). Em 2023, as pastagens no Brasil abrangeram aproximadamente 161 milhões de hectares (ABIEC, 2024).

As pastagens também desempenham papel social, promovendo a geração de empregos e a fixação de famílias no campo. Do ponto de vista ambiental, pastagens bem manejadas contribuem para aumentar a produção sem necessidade de expansão de área, minimizando o desmatamento e permitindo o sequestro de carbono no solo, o que reduz a pegada de carbono dos sistemas de produção (Tessema et al., 2021). Assim, avanços no manejo sustentável das pastagens trazem benefícios sociais, econômicos e ambientais tanto para Brasil quanto para o mundo.

A formulação de dietas e planos nutricionais adequados é essencial para o sucesso de sistemas de produção de ruminantes, tanto de corte quanto de leite. Em condições tropicais, a composição química das pastagens apresenta elevada variabilidade ao longo dos ciclos produtivos, reflexo do rápido crescimento vegetativo e da rápida maturação das espécies forrageiras típicas dessas regiões (Carnevali et al., 2021). Essa dinâmica reforça a importância de monitorar continuamente o valor nutritivo das forragens, garantindo um balanceamento nutricional mais preciso e eficiente nos diferentes estágios de desenvolvimento da planta.

2.2 Gramíneas *Urochloa* spp.

O valor nutricional das gramíneas *Urochloa* spp. (syn. *Brachiaria* spp.) é modificado conforme a planta amadurece (Oliveira et al., 2024). As espécies do gênero *Urochloa*, nativas da África, adaptaram-se bem ao clima brasileiro e dominam 80 a 90% das pastagens no país, sendo as mais comuns *U. decumbens* e *U. brizantha* (Corrêa et al., 2020; Florindo et al., 2014; Paciullo et al., 2007). As espécies desse gênero são amplamente valorizadas na pecuária devido à sua elevada produção de matéria seca, adaptação a diversas condições de solo, clima e manejo, além da facilidade de implantação e alta persistência, viabilizam a alta produção de carne e leite (Ambiel et al., 2008).

Essas forrageiras também se destacam pelo bom valor nutricional, crescimento contínuo durante grande parte do ano, incluindo períodos de estiagem, e resistência ao pisoteio, apresentando ainda baixa suscetibilidade a doenças (Costa et al., 2005). Dentre as gramíneas desse gênero, ocorre variabilidade de forrageiras através de híbridos devido ao cruzamento entre as espécies, resultando em cultivares melhores adaptadas, com maior produtividade e qualidade nutricional, como adaptação a seca (Sollenberger et al., 2019). Portanto, a análise da composição química em diferentes fases de desenvolvimento é crucial tornando essencial o desenvolvimento de técnicas confiáveis e acuradas.

2.3 Espectroscopia de Infravermelho Próximo

A NIRS é uma tecnologia promissora, que utiliza a absorção de energia eletromagnética na região do infravermelho para detectar e quantificar constituintes dos alimentos (Dias; Nunes; Borba, 2023; Hart et al., 2020; Lovett et al., 2005; Oliveira et. al, 2024; Serrano et al., 2020). Essa técnica consiste na interação da luz em diferentes comprimentos de onda com ligações químicas, chamado de espectro do infravermelho próximo, compreendendo de 780 a 2500 nm (Siesler et al., 2008). O intervalo de comprimentos de onda pode variar dentro do especificado, dependendo do modelo e aplicação do equipamento. As informações contidas na reflexão difusa permitem identificar ligações químicas presentes na amostra, tais como -CH, -OH, -NH e -SH (Corson et al., 1999). A partir do espectro, transformações matemáticas e modelos estatísticos de predição são gerados, transformando informações da interação da luz com a amostra em estimativas de composição quantitativa ou indicadores qualitativos (Torniainen et al., 2020). Apesar de conhecidamente promissora, a tecnologia deve ser adaptada para contextos específicos, de modo que o sucesso da transformação do espectro em informação aplicável depende de diversos fatores.

A energia eletromagnética é absorvida pelas ligações covalentes presentes nas substâncias orgânicas das amostras, induzindo vibrações específicas em consonância com determinados comprimentos de onda (Skoog et al., 2006). A quantidade de radiação absorvida, bem como os comprimentos de onda correspondentes, é característica de cada tipo de ligação química covalente existente na amostra, possibilitando a identificação e a quantificação das moléculas orgânicas por meio do padrão espectral gerado pela interação com a luz incidente (Vogel, 1992). No contexto da espectroscopia, a determinação da concentração de substâncias pode ser realizada pela aplicação da Lei de *Lambert-Beer*, que relaciona a absorção da luz ao coeficiente de extinção da substância e ao caminho óptico percorrido pela luz na amostra (Gobrecht et al., 2015).

Quando comparada aos métodos laboratoriais convencionais, a NIRS é preferível em termos de precisão, velocidade e custo por unidade de análise, desde que devidamente calibrada (Minet et al., 2021). Entretanto, é necessário ter amostras padrão que tenham sido analisadas por meio de métodos químicos tradicionais (Canesin; Fiorentini; Berchielli, 2012) e algumas amostras podem apresentar interferências que podem afetar os resultados, como variações na temperatura, umidade e conteúdo de matéria orgânica (Williams; Norris, 2001).

2.4 Desenvolvimento de Modelos Preditivos na NIRS

A quimiometria é uma área que aplica métodos estatísticos, matemáticos e computacionais para otimizar procedimentos analíticos e extrair o máximo de informação, especialmente a partir de dados multivariados de origem química ou não. (Otto, 2023; Trygg; Holmes; Lundstedt, 2007). Na NIRS, a quimiometria é aplicada aos espectros a fim de filtrar informações relevantes devido à influência de características como tamanho das partículas, textura, temperatura, teor de umidade, dispersão da luz e outras possíveis interferências (Fernández-Cabanás et al., 2006).

Uma abordagem comum para minimizar essas interferências e obter resultados precisos é a calibração multivariada, que usa um conjunto de amostras com valores conhecidos para calibrar o equipamento e estimar os valores desconhecidos (Tian et al., 2021). No entanto, é crucial reconhecer que outros fatores podem impactar a acurácia dos modelos, incluindo os valores selecionados, a quantidade de espectros utilizados para representar o modelo, o

equipamento utilizado, fatores externos, a habilidade do usuário, o número de amostras representativas, e assim por diante (Peirs et al., 2003; Wang; Veltkamp; Kowalski, 1991).

A análise quantitativa na NIRS baseia-se na correlação entre a absorção da radiação em bandas específicas do espectro e a concentração dos analitos de interesse, fundamentando-se em calibrações previamente estabelecidas (Williams; Norris, 2001). Além da aplicação quantitativa, a NIRS também é utilizada em análises qualitativas, permitindo a identificação de determinados grupos funcionais ou compostos na amostra, a partir da comparação dos espectros obtidos com bancos de dados de referência (Workman Jr; Weyer, 2012).

Existem etapas fundamentais no processo de desenvolvimento de modelos para medições por NIRS. A primeira etapa consiste na aquisição dos dados espectrais. Em seguida, os dados são submetidos à etapa de pré-processamento para eliminar ruídos e variações espectrais causadas por diferentes fatores. Após o pré-processamento dos dados, constrói-se o modelo de calibração, utilizando espectros tratados para simplificar a complexidade e melhorar a eficiência dos métodos de regressão. Assim, é feita a construção dos modelos de calibração usando um conjunto de amostras com concentrações conhecidas que foram analisadas em métodos de referência adequados. (Cen; He, 2007).

A análise multivariada é essencial para reduzir variáveis e identificar amostras discrepantes, extraindo o máximo de informações dos dados (Sena et al., 2017; Varmuza; Filzmoser, 2016). Na análise por NIRS, destaca-se o uso de métodos como a Regressão por Mínimos Quadrados Parciais (PLSR), que converte espectros e dados de referência em variáveis latentes (LVs), e a Regressão de Componentes Principais (PCR), que organiza as informações em componentes principais (PCs), otimizando a interpretação dos dados (Miller; Miller, 2018; Parrini et al., 2019).

2.5 Processamento Físico de Amostras e Aplicação de Equipamentos NIRS Portáteis

A aplicação da NIRS para prever características nutricionais em amostras frescas tem ganhado destaque por ser uma alternativa econômica às análises tradicionais. Além disso, evita os impactos do processo de secagem em estufa, como perdas de carboidratos solúveis e ocorrência de reações de Maillard (Deinum; Maassen, 1994; Lovett et al., 2005; Van Soest, 1994). Porém, amostras frescas apresentam desafios devido aos fortes sinais de absorção da água, que podem interferir em outras características espectrais e gerar respostas não lineares (Lovett et al., 2005). Por isso, amostras secas geralmente apresentam resultados mais precisos, com menor erro de calibração. Na composição dos alimentos para animais há uma ampla diversidade de partículas com características distintas de forma, tamanho e densidade. Essas diferenças podem ocasionar mudanças nas propriedades de reflexão e dispersão da luz durante a análise por NIRS (Ikoyi; Younge, 2020; Lovett et al., 2005; Workman Jr, 1996). Apesar dessas limitações, a utilização da NIRS em amostras frescas apresenta vantagens operacionais, ao dispensar etapas convencionais de preparo físico, como a pré-secagem e a moagem (Fernandes et al., 2023).

Atualmente, há uma crescente disponibilidade de NIRSp, graças ao avanço tecnológico que promoveu o desenvolvimento desses instrumentos compactos e facilmente transportáveis (Aenugu et al., 2011; Pasquini, 2003). Esses aparelhos têm se destacado como uma alternativa promissora para a determinação da composição da forragem no momento do consumo pelos animais, permitindo análises rápidas e em campo. Porém, a alta umidade das amostras pode interferir na absorção do infravermelho próximo, afetando a precisão das estimativas, e fatores

como a faixa espectral do equipamento, a intensidade da luz e o modo de detecção da absorbância podem influenciar a qualidade dos resultados (Béc et al., 2020; Oliveira et al., 2024).

Assim, o grau de processamento físico das amostras exerce influência direta sobre a qualidade dos espectros obtidos e, conseqüentemente, sobre a precisão das calibrações desenvolvidas na NIRS. Enquanto o processamento mais intenso, como a secagem e moagem, tende a reduzir a variabilidade espectral associada à umidade e ao tamanho de partícula, melhorando a robustez dos modelos, o uso de amostras frescas, embora operacionalmente vantajoso, ainda apresenta limitações importantes relacionadas à interferência da água e à heterogeneidade física da forragem. Portanto, compreender e controlar o impacto do processamento físico torna-se essencial para maximizar o desempenho da NIRS, especialmente no contexto de análises rápidas e portáteis em condições de campo.

3 MATERIAL E MÉTODOS

Todos os procedimentos envolvendo animais foram aprovados pelo Comitê 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 Quantitativo de Amostras

De janeiro/2024 a junho/2024 foram coletadas 121 amostras independentes de gramíneas do gênero *Urochloa* (Tabela 1) em três municípios brasileiros, abrangendo diferentes condições climáticas e geográficas.

As coletas no município de Seropédica (n=89) foram realizadas nas imediações da Universidade Federal Rural do Rio de Janeiro (UFRRJ) e no campo agrostológico da UFRRJ (22° 46' 26.6" S, 43° 41' 14.7" W), no estado do Rio de Janeiro. O clima da região é classificado como tipo Aw (tropical com estação seca no inverno), segundo Köppen, com temperatura média anual de 24,5 °C e precipitação média anual de 1213 mm (Carvalho et al., 2011).

No estado de Minas Gerais, as coletas foram realizadas nos campos agrostológicos da Universidade Federal de Lavras (n=6; 21° 13' 49.8" S, 44° 58' 11.6" W) e da Universidade Federal de Viçosa (n=26; 20° 46' 28.4" S, 42° 51' 29.9" W). Ambas as localidades apresentam clima do tipo Cwa (mesotérmico úmido, com verões chuvosos e invernos secos), com temperaturas médias anuais de 20,4 °C e 19 °C, respectivamente, e precipitações médias anuais de 1460 mm e 1248 mm (Dantas; Carvalho; Ferreira, 2007; Silva et al., 2003).

Tabela 1. Quantitativo de espécies e cultivares coletadas do gênero *Urochloa*.

Nome científico	Quantidade
<i>U. decumbens</i> cv. Basilisk	42
<i>U. brizantha</i> cv. Marandu	13
<i>U. ruziziensis</i>	13
<i>U. humidicola</i> cv. Llanero	11
<i>U. híbrida</i> cv. Mulato II	8
<i>U. híbrida</i> cv. Mulato I	7
<i>U. brizantha</i> cv. BRS Piatã	5
<i>U. brizantha</i> cv. BRS Paiaguás	3
<i>U. brizantha</i> cv. Xaraés	2
<i>U. brizantha</i> cv. MG-4	2
<i>U. humidicola</i> cv. Tupi	2
<i>U. mutica</i> x <i>U. arrecta</i>	2
<i>U. híbrida</i> cv. Camello	2
<i>U. híbrida</i> cv. Sabiá	2
<i>U. decumbens</i> cv. Ipean	1
<i>U. humidicola</i> cv. Comum	1
<i>U. humidicola</i> cv. Quicuio-do-Amazonas	1
<i>U. mutica</i>	1
<i>U. brizantha</i> cv. BRS Itaporã	1
<i>U. híbrida</i> cv. Cayana	1
<i>U. híbrida</i> cv. Mavuno	1

3.2 Coletas e Amostragem

As amostras foram coletadas com corte a 50% da altura do dossel, visando representar a fração potencialmente consumida pelos animais. Cada amostra totalizou aproximadamente 500 g. O material foi picado em 2 a 3 cm com tesoura e homogeneizado. Em seguida, foram coletadas seis amostragens espectrais aleatórias em diferentes pontos, utilizando um NIRSp (MyNIR, *Spectral Solutions*, São Paulo, Brasil), semelhante ao Innospectra NIR-S-G1 descrito por Berzaghi et al. (2021). O equipamento abrange de 900 a 1700 nm e possui lâmpada de 1,4 W, resolução óptica de 10–12 nm, relação sinal-ruído de 5000:1 e detector InGaAs de 1 mm, sendo previamente calibrado com um padrão de refletância difusa. Após obtenção de espectro, as amostras foram pré-secas em estufa por 72h (método G-001/2; Detmann et al., 2021), obtendo-se a amostra seca ao ar, e outras seis amostragens espectrais foram coletadas da mesma forma que na amostra fresca. Posteriormente, as amostras foram moídas a 2 mm e 1 mm em moinho de facas tipo Willey e seis amostragens espectrais aleatórias foram obtidas novamente em cada nível de moagem. As amostras moídas foram armazenadas em frascos plásticos herméticos para as análises laboratoriais.

Assim, foram obtidas amostragens espectrais em quatro graus de processamento físico das amostras (Figura 1): a) frescas após coleta e picagem com tesoura (FR); b) secas após secagem em estufa por 72h (SC); c) secas e moídas a 2 mm (SM2); d) secas e moídas a 1 mm (SM1).

Para a coleta das amostragens espectrais das amostras FR e SC, antes da moagem, padronizou-se o uso de um frasco plástico branco de 8,3 cm de diâmetro e 5,9 cm de altura, onde adicionou-se amostra até o completo preenchimento. Para as amostras moídas, utilizou-se um recipiente plástico de 7 cm de diâmetro e 1,5 cm de altura.



Figura 1. Coleta das amostragens espectrais nos 4 graus de processamento de amostra: (A) fresca; (B) seca; (C) seca e moída a 2 mm; (D) seca e moída a 1 mm.

Fonte: Arquivo pessoal.

3.3 Análises Laboratoriais

Para obter-se os valores de referência os modelos de calibração foram analisados quanto aos teores de: : matéria seca (MS – método G-003/1; Detmann et al., 2021), matéria orgânica (MO – método M-001/2; Detmann et al., 2021), nitrogênio pelo método Kjeldahl (N – método N-001/2; Detmann et al., 2021), fibra insolúvel em detergente neutro em autoclave (FDN – método F-002/2; Detmann et al., 2021) sem adição de α -amilase, FDN corrigida para cinzas (FDNc – método M-002/2; Detmann et al., 2021), FDN indigestível após 288h de incubação (FDNi – método F-009/2; Detmann et al., 2021), digestibilidade *in vitro* da MS (DIVMS – método G-008/1; Detmann et al., 2021), digestibilidade *in vitro* da FDN (DIVFDN) e rendimento de metano *in vitro* (*in vitro*-CH₄) adaptada do método descrito por Oliveira et al. (2018). Para a análise da DIVFDN, aplicaram-se os mesmos procedimentos de incubação adotados para a DIVMS (método G-008/1; Detmann et al., 2021) com posterior análise da FDN (método F-002/2; Detmann et al., 2021).

As análises de DIVMS e DIVFDN foram realizadas através de incubadora Daisy II (Ankom Technology Corporation Fairport, NY, USA). Além disso, para as análises de DIVMS,

DIVFDN e FDNi foram utilizadas três vacas Girolando (594±42 kg de peso vivo) fistuladas no rúmen e para *in vitro*-CH₄ duas vacas Holandesas (856±5 kg de peso vivo) fistuladas no rúmen. As dietas basais constituíram-se de silagem de sorgo e concentrado (70:30) e silagem de milho e concentrado (60:40), respectivamente.

Para a realização da análise de *in vitro*-CH₄, pesou-se 0,5 g de amostra seca ao ar moída a 1 mm diretamente nos frascos de fermentação âmbar de 50 mL. O ensaio foi realizado em duplicata e utilizou-se 3 brancos por rodada. Preparou-se o meio de cultura (tampão, macromineral, micromineral, solução de resazurina, solução redutora-meio B) de acordo com as recomendações de Theodorou et al. (1994). Foi coletado líquido ruminal de duas vacas e armazenou-se em garrafa térmica até o momento da incubação. O meio de cultura foi mantido sob fluxo de CO₂ e o líquido ruminal foi adicionado na proporção 3:1. Em seguida, 25 mL da mistura foram adicionados em cada frasco âmbar e vedou-se com rolhas de silicone e anilhas de alumínio. Após esse processo, zerou-se a fermentação nos frascos com o auxílio de agulha e agitou-se por 2 minutos. Todo o processo foi realizado sob fluxo de CO₂ e em câmara climatizada a 39°C. A mensuração pelo volume de gases produzidos foi realizada por meio de deslocamento de água medido por meio da utilização de aparato vaso comunicante após 24 horas de fermentação. Utilizou-se exetainers de 6,8 mL que foram submetidos a vácuo com o auxílio de uma seringa conectada ao septo, garantindo a remoção do ar interno antes do uso, para o armazenamento de amostras de gases e foram amostrados aproximadamente 15 mL. Após encerrar a fermentação, o resíduo foi filtrado utilizando papel filtro previamente tarado, e após secagem, foi pesado o conjunto pesa filtro + resíduo. A concentração de CH₄ foi determinada por cromatografia gasosa (Cromatógrafo em fase gasosa CG-FID e CG-ECD, Agilent Technologies, modelo 7820A, com *software* de interface EzChrom Elite), conforme descrito por Holtshausen et al. (2009). O rendimento de CH₄ foi estimada em mL g⁻¹ de matéria seca aparentemente degradada (MSDa) e foi calculada a partir da degradação aparente da matéria seca (DAMS; g.kg⁻¹), corrigindo os valores médios dos brancos:

$$DAMS = 1000 \times \frac{MS_i - MS_f}{MS_i}$$

onde MS_i = matéria seca incubada e MS_f = matéria seca residual (mg).

3.4 Análises Estatísticas

Foram calculadas as médias das seis amostragens espectrais para cada nível de processamento da amostra e as curvas foram submetidas a 99 diferentes combinações de pré-processamentos. Os pré-processamentos aplicados incluíram correção de linha de base, normalização e o filtro Savitzky-Golay, com variações em parâmetros como tamanho das janelas (7 e 11), ordens polinomiais (2 e 3), ordens derivativas (0, 1 e 2) e deltas (1 e 2). Além dos pré-processamentos, adicionou-se o uso dos dados espectrais brutos, totalizando 100 abordagens avaliadas.

Após a aplicação dos pré-processamentos, as calibrações espectrais foram realizadas utilizando PLSR, empregando validação cruzada *leave-one-out* (LOOCV) para avaliar a robustez dos modelos. As métricas de desempenho calculadas incluíram raiz do erro quadrático médio (RMSEP), raiz do erro quadrático médio de predição em % do valor médio observado (RMSEP%), coeficiente de determinação da LOOCV (*R*² *test*), coeficiente de determinação da calibração (*R*² *train*), inclinação da reta (*slope*), intercepto entre valores preditos e observados e erro médio absoluto (MAE). Todas as análises e processamentos dos dados foram conduzidos por meio dos *softwares* Python (versão 3.12.6) e R (versão 4.4.1), como descrito por Torniainen

et al. (2020). A Figura 2 apresenta um esquema ilustrativo das etapas envolvidas para a avaliação dos modelos.




Figura 2. Fluxograma das etapas de processamento físico das amostras de *Urochloa* spp., aquisição espectral, calibração e análises laboratoriais. As amostras foram avaliadas nos estados fresca, seca, seca e moída a 2 mm e seca e moída a 1 mm, com seis amostragens espectrais realizadas para cada condição. O modelo de calibração foi construído utilizando validação cruzada *leave-one-out* (LOOCV) e avaliado por métricas de desempenho, incluindo raiz do erro quadrático médio (RMSEP), raiz do erro quadrático médio de predição em % do valor médio observado (RMSEP%), coeficiente de determinação da validação (R² test), coeficiente de determinação da calibração (R² train), inclinação da reta (*Slope*), intercepto e erro médio absoluto (MAE). As análises laboratoriais determinaram o teor de matéria seca (MS), matéria orgânica (MO), nitrogênio (N), fibra insolúvel em detergente neutro (FDN), FDN corrigida para cinzas (FDNc), FDN indigestível (FDNi), digestibilidade *in vitro* da MS (DIVMS), digestibilidade *in vitro* da FDN (DIVFDN) e rendimento de metano *in vitro* (*in vitro*-CH₄).

Os valores das métricas foram avaliados considerando que modelos com menor RMSEP, RMSEP% e MAE, além de maiores R² test e R² train, apresentam um desempenho preditivo mais preciso. O RMSEP foi utilizado para quantificar o erro médio das predições, sendo desejáveis valores menores, enquanto o RMSEP% permitiu avaliar esse erro em relação à média observada da variável, facilitando comparações entre variáveis com diferentes escalas. O R² train indicou o ajuste do modelo aos dados de calibração, enquanto o R² test avaliou a capacidade de generalização do modelo, sendo valores maiores preferíveis. O valor de *slope* foi analisado para verificar a proximidade entre valores preditos e observados, sendo idealmente

próximo de 1, e o intercepto foi considerado para avaliar possíveis vieses no modelo, com valor ideal próximo de zero. O MAE foi utilizado para quantificar a magnitude média dos erros absolutos, auxiliando na comparação entre os diferentes graus de processamento.

4 RESULTADOS

4.1 Caracterização das Amostras

Os valores de altura, composição bromatológica, digestibilidade e rendimento de metano *in vitro* (valor nutritivo) das amostras de *Urochloa* spp. apresentaram ampla variabilidade, conforme descrito na Tabela 2.

Tabela 2. Valores de média, mínimo, máximo e desvio padrão da altura, composição bromatológica via úmida, digestibilidade e rendimento de metano *in vitro* (% da matéria seca, salvo indicação).

Variável	Média	Mínimo	Máximo	Desvio Padrão
Altura (cm)	48,37	15,00	105,00	19,32
MS (% da MN)	25,73	15,80	46,08	7,15
MO	91,88	88,33	95,36	1,53
N	1,59	0,63	3,21	0,57
FDN	61,19	45,76	74,49	6,20
FDNc	59,07	43,12	72,14	6,22
FDNi	14,02	8,18	32,31	5,11
DIVMS	76,55	50,97	91,01	8,59
DIVFDN	68,19	39,38	83,50	9,82
<i>in vitro</i> -CH ₄ (mL/g MS degradada)	17,10	9,36	28,42	4,03

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 após 288h de incubação; DIVMS = digestibilidade *in vitro* da MS; DIVFDN = digestibilidade *in vitro* da FDN; *in vitro*-CH₄ = rendimento de metano *in vitro*.

4.2 Análise dos Espectros Brutos

Os espectros brutos individuais das 121 amostras de *Urochloa* spp. (Figura 3), submetidas aos diferentes graus de processamento físico, mostram variabilidade entre as repetições de cada tipo de tratamento, refletida pela dispersão dos espectros. A análise das médias dos espectros por grau de processamento, apresentada na Figura 4, destaca as tendências gerais de absorbância e as diferenças entre os tratamentos, facilitando a comparação entre os efeitos de cada tipo de processamento. Observa-se que a amostra FR (Verde) apresentou maiores valores de absorbância ao longo do espectro, com destaque para uma banda em torno de 1450 nm. A amostra SC (Seco) apresentou absorbância reduzida em relação à amostra FR. As amostras secas e moídas (SM2 e SM1) exibiram menores valores de absorbância e espectros com menor variação de intensidade. A moagem mais fina (SM1) resultou em uma leve redução adicional na absorbância em comparação à SM2.




Figura 3. Espectros brutos individuais de 121 amostras de *Urochloa* spp. submetidas a diferentes graus de processamento físico: amostra fresca, amostra seca, amostra seca e moída a 2 mm (2 mm) e amostra seca e moída a 1 mm (1 mm). As absorbâncias foram obtidas no intervalo de 900 a 1700 nm utilizando espectroscopia no infravermelho próximo portátil.




Figura 4. Médias dos espectros brutos de 121 amostras de *Urochloa* spp. submetidas a diferentes graus de processamento físico: amostra fresca, amostra seca, amostra seca e moída a 2 mm (2 mm) e amostra seca e moída a 1 mm (1 mm). As medidas de absorbância foram obtidas no intervalo de 900 a 1700 nm utilizando espectroscopia no infravermelho próximo portátil.

4.3 Desempenho dos Modelos de Calibração

Os modelos de calibração multivariada mostraram variações no desempenho conforme o grau de processamento físico das amostras de *Urochloa* spp. (Tabela 3).

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

Grau de processamento	RMSEP	RMSEP%	R ² <i>train</i>	R ² <i>test</i>	<i>Slope</i>	Intercepto	MAE
Matéria seca (MS)							
Fresca	2,37	9,21	0,88	0,82	0,97	0,83	0,0289
Seca	2,36	9,17	0,87	0,80	0,96	1,16	0,0073
2 mm	2,35	9,13	0,85	0,78	0,96	1,12	0,0189
1 mm	2,03	7,89	0,90	0,84	0,96	0,99	0,0568
Matéria orgânica							
Fresca	0,97	1,06	0,53	0,40	0,87	12,30	0,0134
Seca	0,84	0,91	0,64	0,51	0,89	10,49	0,0134
2 mm	0,78	0,85	0,68	0,59	0,94	5,45	0,0064
1 mm	0,78	0,85	0,79	0,58	0,81	17,28	0,0424
Nitrogênio							
Fresca	0,31	19,50	0,74	0,55	0,85	0,23	0,0045
Seca	0,31	19,50	0,79	0,58	0,85	0,23	0,0001
2 mm	0,15	9,43	0,98	0,86	0,90	0,15	0,0030
1 mm	0,20	12,58	0,99	0,75	0,80	0,30	0,0139
Fibra insolúvel em detergente neutro (FDN)							
Fresca	3,90	6,37	0,51	0,33	0,81	11,76	0,0107
Seca	3,50	5,72	0,72	0,50	0,80	12,10	0,0435
2 mm	2,51	4,10	0,96	0,73	0,81	11,86	0,1710
1 mm	1,70	2,78	0,98	0,87	0,96	2,59	0,0800
FDN corrigida para cinzas							
Fresca	3,88	6,57	0,52	0,34	0,81	10,95	0,0175
Seca	3,49	5,91	0,76	0,51	0,80	11,94	0,1311
2 mm	2,61	4,42	0,95	0,74	0,82	10,60	0,1521
1 mm	1,79	3,03	0,98	0,86	0,93	3,89	0,0471
FDN indigestível							
Fresca	2,03	14,48	0,81	0,72	0,93	1,01	0,0200
Seca	1,73	12,34	0,91	0,78	0,92	1,07	0,0400
2 mm	1,86	13,27	0,89	0,72	0,92	1,19	0,0134
1 mm	1,61	11,48	0,84	0,79	0,97	0,43	0,0061
Digestibilidade <i>in vitro</i> da MS							
Fresca	4,52	5,90	0,68	0,52	0,85	11,70	0,0300
Seca	4,28	5,59	0,80	0,62	0,86	10,81	0,0631
2 mm	3,84	5,02	0,81	0,64	0,89	8,24	0,0791
1 mm	3,36	4,39	0,84	0,74	0,93	5,50	0,1340
Digestibilidade <i>in vitro</i> da FDN							
Fresca	4,98	7,30	0,71	0,54	0,87	9,06	0,0422
Seca	4,29	6,29	0,87	0,70	0,91	6,41	0,0834
2 mm	4,56	6,69	0,83	0,65	0,92	5,17	0,2086
1 mm	3,92	5,75	0,84	0,76	0,94	3,84	0,0856
mL de CH ₄ /g de MS degradada <i>in vitro</i>							
Fresca	3,21	18,77	0,12	0,03	0,52	8,15	0,0168
Seca	2,89	16,90	0,28	0,21	0,86	2,33	0,0044
2 mm	2,75	16,08	0,80	0,39	0,69	5,29	0,0504
1 mm	2,50	14,62	0,83	0,39	0,55	7,69	0,1144

RMSEP = raiz do erro quadrático médio predito; 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 LOOCV; *Slope* = inclinação da reta; MAE = erro médio absoluto.

Para a predição dos valores de MS (Figura 5), as amostras FR apresentaram as predições mais precisas, com R^2_{test} de 0,82, RMSEP de 2,37 e RMSEP% de 9,21, indicando maior acurácia e menor erro de predição. O R^2_{train} de 0,88 e o *slope* de 0,97 refletiram elevado ajuste do modelo aos dados de calibração, com intercepto de 0,83 e MAE de 0,0289. As amostras SC apresentaram valores semelhantes de R^2_{test} (0,80) e RMSEP (2,36), com *slope* de 0,96 e intercepto de 1,16. As amostras SM1 e SM2 apresentaram R^2_{test} de 0,84 e 0,78, e RMSEP de 2,03 e 2,35, respectivamente, mantendo alinhamento adequado entre valores preditos e observados.




Figura 5. Regressão linear entre valores preditos e observados para MS em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.

Na predição da MO (Figura 6), as amostras SM2 e SM1 apresentaram os maiores ajustes, com R^2_{test} de 0,59 e 0,58, respectivamente, e RMSEP de 0,78 para ambas. As amostras SM2 exibiram alinhamento próximo do ideal (*slope* = 0,94; intercepto = 5,45) e leve superestimação, enquanto SM1 demonstraram maior dispersão (*slope* = 0,81; intercepto = 17,28) e tendência à subestimação em altos valores. As amostras SC (R^2_{test} = 0,51) e FR (R^2_{test} = 0,40) mantiveram a tendência linear, porém com menor precisão e maior variabilidade preditiva.




Figura 6. Regressão linear entre valores preditos e observados para MO em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.

Para o teor de N (Figura 7), as amostras SM2 apresentaram R^2 test de 0,86, RMSEP de 0,15 e RMSEP% de 9,43, sugerindo forte capacidade de predição e erro percentual reduzido. O *slope* de 0,90 e intercepto de 0,15 reforçam a proximidade da relação linear ideal, com MAE de 0,0030 indicando erro absoluto baixo. As amostras SM1 apresentaram R^2 test de 0,75, RMSEP de 0,20, *slope* de 0,80, intercepto de 0,30 e MAE de 0,0139, indicando ajuste satisfatório, mas com maior dispersão. As amostras SC e FR apresentaram R^2 test de 0,58 e 0,55, ambos com *slope* de 0,85, intercepto de 0,23 e MAE de 0,0001 (SC) e 0,0045 (FR), demonstrando tendência preservada, mas com menor capacidade preditiva.




Figura 7. Regressão linear entre valores preditos e observados para N em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.

As variáveis relacionadas à fibra (FDN, FDNc e FDNi; Figura 8, 9 e 10) apresentaram maior desempenho preditivo nas amostras SM1, com R^2_{test} de 0,87, 0,86 e 0,79, respectivamente, *slopes* próximos de 1 e erros reduzidos (RMSEP% de 2,78, 3,03, 11,48, respectivamente), indicando elevada acurácia e alinhamento linear. As amostras SM2 tiveram desempenho intermediário, com R^2_{test} entre 0,72 e 0,74, *slopes* de 0,81 a 0,92 e interceptos mais altos, sugerindo maior dispersão. As amostras SC e FR mostraram limitações na predição de FDN (R^2_{test} de 0,50 (SC) e 0,33 (FR)) e FDNc (R^2_{test} de 0,51 (SC) e 0,34 (FR)), mas para FDNi apresentaram valores mais consistentes, com R^2_{test} de 0,78 (SC) e 0,72 (FR), mantendo a tendência preditiva mesmo com maior erro absoluto. Isso sugere menor sensibilidade do FDNi ao grau de processamento físico.




Figura 8. Regressão linear entre valores preditos e observados para FDN em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.




Figura 9. Regressão linear entre valores preditos e observados para FDNc em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.




Figura 10. Regressão linear entre valores preditos e observados para FDNi em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.

Na predição de DIVMS e DIVFDN (Figuras 11 e 12), as amostras SM1 apresentaram os maiores coeficientes de determinação (R^2 test de 0,74 e 0,76, respectivamente), com *slopes* próximos de 1 (0,93 e 0,94) e erros moderados (RMSEP% de 4,39 e 5,75), indicando bom alinhamento e predição consistente. As amostras SM2 e SC mostraram desempenho intermediário, com R^2 test entre 0,62 e 0,70 e *slopes* de 0,86 a 0,92, mantendo a tendência linear, embora com maior dispersão e erros mais elevados. Já as amostras FR apresentaram os menores R^2 test (0,52 em DIVMS e 0,54 em DIVFDN), com *slopes* de 0,85 e 0,87 e baixos MAE, refletindo menor precisão, mas com manutenção razoável da tendência preditiva.




Figura 11. Regressão linear entre valores preditos e observados para DIVMS em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.




Figura 12. Regressão linear entre valores preditos e observados para DIVFDN em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R^2 indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.

Por fim, para a predição de *in vitro*-CH₄ (Figura 13), as amostras SM1 e SM2 apresentaram R^2 test de 0,39 e menor erro de predição (RMSEP% de 14,62 e 16,08) em comparação às amostras SC (R^2 test de 0,21, RMSEP% de 16,90), embora com baixa capacidade preditiva e alta variabilidade. As amostras FR tiveram o desempenho mais limitado (R^2 test de 0,03, RMSEP% de 18,77), indicando restrição na predição dessa variável em material fresco.




Figura 13. Regressão linear entre valores preditos e observados para *in vitro*-CH₄ em amostras: (A) frescas; (B) secas; (C) secas e moídas a 2 mm; (D) secas e moídas a 1 mm. A linha azul representa o ajuste da regressão linear (equação e R² indicados), enquanto a linha vermelha tracejada representa o ajuste perfeito (1:1). Cada ponto cinza corresponde a uma amostra da validação.

De modo geral, as amostras FR apresentaram menor precisão nas predições em comparação às amostras secas e moídas, o que foi evidenciado pelos menores valores de R² *test* e maiores valores de RMSEP e RMSEP% na maioria das variáveis analisadas. Entretanto, para as variáveis MS (R² *test* = 0,82; RMSEP = 2,37), N (R² *test* = 0,55; RMSEP = 0,31) e FDNi (R² *test* = 0,72; RMSEP = 2,03), a calibração utilizando amostras frescas resultou em métricas que indicam tendência preditiva preservada e viabilidade de uso, especialmente para FDNi e MS. No caso de N, apesar do R² *test* mais baixo, o *slope* de 0,85 e o MAE de 0,0045 sugerem que o modelo ainda apresentou alinhamento linear satisfatório, com erro absoluto reduzido.

As amostras SC preservaram a tendência linear entre valores observados e preditos, com *slope* próximo de 1 em variáveis como MS (*slope* = 0,96) e FDNi (*slope* = 0,92). No entanto, apresentaram desempenho preditivo inferior às amostras moídas, especialmente para MO (R² *test* = 0,51; RMSEP = 0,89), FDN (R² *test* = 0,50; RMSEP = 3,50) e FDNc (R² *test* = 0,51; RMSEP = 3,49). Apesar disso, os valores de RMSEP e R² *test* para MS (R² *test* = 0,80; RMSEP = 2,36) e FDNi (R² *test* = 0,78; RMSEP = 2,36) indicam que as predições para as amostras SC ainda podem ser consideradas viáveis para aplicação prática, especialmente em variáveis com menor sensibilidade ao grau de processamento físico.

As amostras SM2 mostraram desempenho preditivo consistente para variáveis como MO e N, com R^2_{test} variando de 0,59 a 0,86 e RMSEP% de 0,85 e 9,43, respectivamente. Com valores de *slopes* próximos de 1 indicaram bom alinhamento entre os valores observados e preditos, embora os interceptos fossem mais altos em comparação às amostras SM1. As amostras SM1 apresentaram o desempenho preditivo com os maiores valores de R^2_{test} e os menores valores de RMSEP para a maioria das variáveis. As predições mais precisas foram observadas para MS, FDN, FDNc, FDNi, DIVMS e DIVFDN, com os maiores valores de R^2_{test} (até 0,87), *slopes* próximos de 1 e menores erros absolutos e relativos (RMSEP% até 11,48), indicando bom alinhamento entre valores observados e preditos.

4 DISCUSSÃO

O presente estudo teve como objetivo avaliar a capacidade preditiva de um NIRSp de baixo custo para amostras de *Urochloa* spp. submetidas a diferentes graus de processamento, com foco na viabilidade do uso para predição de valores de composição bromatológica, digestibilidade e rendimento de metano *in vitro*. Este tipo de ferramenta pode ser de grande utilidade em sistemas de produção de ruminantes em pastejo, oferecendo uma solução acessível e prática para a análise nutricional em campo.

A altura média de manejo padrão para as espécies *decumbens*, *brizantha* cv. Marandu e *ruzizienses* é de 20, 30 e 30 cm, respectivamente (Fidalski; Tormena; Alves, 2013; Santos et al., 2009; Sbrissia; Silva, 2008), valores abrangidos pelas amostras coletadas. Os valores extremos, como 105 cm, são importantes para a obtenção de espectros associados a plantas em estágios mais avançados de maturação, contribuindo para uma caracterização espectral mais abrangente. Todos os componentes avaliados (MS, MO, N, FDN, FDNc, FDNi, DIVMS, DIVFDN e *in vitro*-CH₄) apresentaram valores que abrangem as médias reportadas na literatura para *Urochloa* spp. (Beterro et al., 2021; Castro et al., 2009; Guimarães et al., 2023; Lopes et al., 2010; Meale et al., 2012; Pamo et al., 2007; Santos et al., 2004; Sousa et al., 2007), além de concentrações superiores e inferiores a essas referências. Essa abrangência dos valores observados reforça a validade da prova de conceito para a utilização do NIRSp na análise de amostras para o gênero.

O processamento físico das amostras demonstrou impacto direto na acurácia e precisão das calibrações. A secagem reduziu as interferências espectrais causadas pela umidade, resultando em calibrações mais consistentes. A remoção da umidade não apenas minimiza o ruído espectral, mas também facilita a detecção de bandas relacionadas aos constituintes da planta (Ikoyi; Younge, 2020). Embora a secagem tenha reduzido a interferência espectral da água, os resultados indicam que essa etapa, isoladamente, não garantiu o desempenho preditivo observado nas amostras secas e moídas. As amostras apenas secas (SC) apresentaram, por exemplo, R² test de 0,50 para FDN, inferior ao valor obtido para SM1 (0,87). A moagem a 1 mm (SM1) promoveu calibrações mais consistentes, refletidas pelos menores RMSEP (1,70 para FDN), reforçando o papel da homogeneização física no aumento da sensibilidade espectral e na melhoria do ajuste dos modelos (Lovett et al., 2005).

A água apresenta forte absorbância em duas regiões características do espectro, aproximadamente em 1470 e 1900 nm, além de absorbância em outras faixas (Ji; Viscarra Rossel; Shi, 2015; Tsenkova et al., 2018), explicando o pico de absorção entre 1400 e 1600 nm na média dos espectros em amostras verdes (FR; Figura 4). Assim, a elevada absorção de luz em regiões específicas do espectro associadas a água pode mascarar os sinais característicos dos compostos de interesse, ocultando bandas de absorbância fracas e deslocando outras bandas de absorbância, o que dificulta a construção de modelos robustos e explicando a maior interferência (Murphy et al., 2022; Tsenkova et al., 2018). Para predição da MS, a água atuou como um indicativo inversamente proporcional à variável, favorecendo os modelos obtidos com amostras FR. De fato, essas apresentaram desempenho superior na predição de MS (R² test = 0,82; RMSEP = 2,37; RMSEP% = 9,21), indicando boa capacidade preditiva mesmo com alto teor de umidade.

O teor de cinzas, relacionado a predição de MO, é um parâmetro desafiador para NIRS, pois os minerais não apresentam absorção direta na região do infravermelho próximo (Reddersen; Fricke; Wachendorf, 2013). Porém, contaminação por solo pode interferir na linha de base do espectro na faixa de 1100–1300 nm (Paul, 1990). Em estudo conduzido para predição do teor de cinzas por NIRS em forragem e silagem frescas este teor foi limitado devido à umidade, variabilidade estrutural e contaminação por solo, resultando em R^2 inferiores a 0,70 e baixa precisão preditiva (Reddersen; Fricke; Wachendorf, 2013). Em outro estudo também avaliando forragem fresca e comparando dispositivos portáteis, os resultados para predição de cinzas em silagem de milho indicaram um R^2 de 0,37 e um RMSEP de 0,83 (Cherney; Digman; Cherney, 2021), evidenciando as dificuldades na calibração desses modelos para amostras FR.

Para a variável N, observou-se a relevância das bandas entre 1500–1530 nm e 1640–1680 nm, associadas ao estiramento N-H e C-H (Rukundo et al., 2021). A Figura 4 mostra que a média dos espectros brutos das amostras FR e SC apresentam variações nestas faixas, indicando a presença de sinais úteis para a predição de N. Dois NIRSp com faixas espectrais de 320–2500 nm e 900–1700 nm apresentaram desempenho semelhante na predição de proteína bruta (PB) em amostras de forragens e rações moídas a 1 mm ($R^2 = 0,97$; RMSEP = 2,14 e 2,05), apesar das diferenças de alcance espectral (Rukundo et al., 2021). Para predição de N em pastagens, um NIRSp de campo obteve $R^2 = 0,72$ e SECV = 3,9 g/kg MS, indicando precisão aceitável em condições de campo (Reddersen; Fricke; Wachendorf, 2013). Assim, os dados presentes na literatura condizem com as descobertas deste estudo, demonstrando a aplicabilidade da predição aceitável a nível de campo para N em amostras FR.

As frações de fibra (FDN, FDNc e FDNi) se beneficiaram do processamento a 1 mm, com destaque para SM1, que apresentou $R^2 \text{ test} > 0,79$ para as três variáveis e baixos RMSEP. Essas faixas se correlacionam com as regiões espectrais de 1786–2498, 1370–1418, 1649–1670 e 2260–2280 nm, ligadas à lignina e celulose (Serrano et al., 2020). A moagem fina contribuiu para a melhoria na resolução dessas bandas, aumentando a sensibilidade dos modelos (Reddersen; Fricke; Wachendorf, 2013). Em estudo utilizando NIRSp para a avaliação de FDN com amostras de *Urochloa*, secas e moídas, os valores de RMSE variaram entre 1,5 e 2,6 e R^2 entre 0,846 e 0,937, confirmando a precisão das calibrações (Oliveira et al., 2024). Ainda assim, a FDNi obteve desempenho intermediário nas amostras frescas, possivelmente por sua associação a componentes estruturais menos suscetíveis às variações introduzidas pelo teor de umidade.

Variáveis de digestibilidade, como DIVMS e DIVFDN também apresentaram os maiores índices de predição para amostras SM1, evidenciado pelo aumento dos valores de R^2 e pela redução dos RMSEP (DIVMS: $R^2 \text{ test} = 0,74$; RMSEP = 3,36; DIVFDN: $R^2 \text{ test} = 0,76$; RMSEP = 3,92). Uma pesquisa com amostras de forragem moída a 1 mm demonstrou que o NIRS é uma ferramenta eficaz para estimar esses parâmetros, com coeficientes de determinação superiores a 0,90, e que os equipamentos portáteis são capazes de fornecer estimativas confiáveis, ainda que apresentem leve redução na precisão preditiva quando comparado ao espectrofotômetro de bancada (Digman; Cherney; Cherney, 2022). A boa predição desses parâmetros nas amostras SM1 se deve à maior homogeneização física, que favorece a detecção de variações estruturais da fibra relevantes à digestibilidade, como lignina e celulose.

A produção de *in vitro*-CH₄, apresentou menor acurácia preditiva em comparação às demais variáveis, embora as amostras SM1 tenham mostrado desempenho superior ($R^2 \text{ test}$ de 0,39 para SM1 e SM2), com menores erros de predição (RMSEP entre 2,50 e 2,75). A literatura sobre a predição desse parâmetro a partir de forragens utilizando NIRS ainda é escassa, com a maioria dos estudos focando na produção total de gases. Predições de produção de gases em silagens frescas e secas resultaram em R^2 de 0,29 a 0,77, concluindo que a predição de

parâmetros biológicos é menos precisa do que a de parâmetros químicos, possivelmente devido à maior variabilidade inerente aos métodos biológicos, influenciada por diversas fontes de erro experimentais e amostrais que impactam a calibração (Dias; Nunes; Borba, 2023).

Em síntese, os resultados deste estudo demonstram que o processamento físico das amostras teve um papel determinante na qualidade das predições obtidas com o NIRSp. A secagem reduziu interferências da umidade, mas foi a moagem fina (SM1) que proporcionou os maiores ajustes dos modelos, evidenciando a importância da homogeneização para a análise espectral. Ainda assim, observou-se que, para variáveis como MS, N e FDNi, o equipamento portátil foi capaz de gerar predições aceitáveis mesmo a partir de amostras FR, reforçando sua viabilidade para uso em campo, especialmente em situações de manejo e monitoramento rápido de pastagens. Lacunas importantes permanecem, especialmente na predição de parâmetros de maior complexidade biológica, como o *in vitro*-CH₄, onde a precisão foi limitada. A maior variabilidade associada a esses parâmetros biológicos e o efeito de fatores externos sobre as medições ainda representam desafios para a calibração robusta. Assim, futuros trabalhos devem explorar estratégias de pré-processamento de espectros, ampliação da base de calibração e o uso de técnicas multivariadas mais avançadas para aprimorar a capacidade preditiva para variáveis mais sensíveis, consolidando a aplicação de NIRS portáteis como ferramentas práticas e confiáveis na avaliação nutricional de forragens em sistemas produtivos.

5 CONCLUSÕES

O presente estudo indicou que o NIRSp de baixo custo é uma ferramenta promissora para a predição da composição bromatológica e da digestibilidade de amostras de *Urochloa* spp., especialmente quando associada ao processamento físico das amostras, como secagem e moagem a 1 mm. Esses procedimentos melhoraram significativamente a consistência dos modelos, sobretudo para constituintes fibrosos e digestibilidade. Em condições de campo, a predição de variáveis como MS, N e FDNi apresentou desempenho satisfatório mesmo em amostras frescas, destacando o potencial da tecnologia para uso prático e rápido na rotina de manejo alimentar. Entretanto, a predição de *in vitro*-CH₄ mostrou acurácia limitada, evidenciando a necessidade de mais estudos para o desenvolvimento de calibrações robustas para parâmetros biológicos complexos. De modo geral, os resultados obtidos reforçam o potencial do NIRSp como uma solução acessível e eficiente para o monitoramento nutricional, contribuindo para uma formulação de dietas mais precisa e sustentável em sistemas de produção de ruminantes.

6 REFERÊNCIAS BIBLIOGRÁFICAS

AENUGU, H. P. R. et al. Near infrared spectroscopy—An overview. **International Journal of ChemTech Research**, v. 3, n. 2, p. 825-836, 2011.

AMBIEL, A. C. et al. Agrupamento de acessos e cultivares de três espécies de *Brachiaria* por RAPD. **Acta Scientiarum. Agronomy**, v. 30, p. 457-464, 2008.

BEĆ, K. B. et al. Handheld near-infrared spectrometers: Where are we heading?. **NIR news**, v. 31, n. 3-4, p. 28-35, 2020.

BEEF REPORT 2024 | PERFIL DA PECUÁRIA NO BRASIL - ABIEC. [S. l.], [s. d.]. Disponível em: <https://www.abiec.com.br/publicacoes/beef-report-2024-perfil-da-pecuaria-no-brasil/>. Acesso em: 10 fev. 2025.

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**, v. 182, p. 106013, 2021.

BETTERO, R. V. et al. Indigestible neutral detergent fiber evaluation with incubation in different species. **Archivos de Zootecnia**, v. 70, n. 269, p. 13-19, 2021.

CANESIN, R. C.; FIORENTINI, G.; BERCHIELLI, T. T. Inovações e desafios na avaliação de alimentos na nutrição de ruminantes. **Revista Brasileira de Saúde e Produção Animal**, v. 13, p. 938-953, 2012.

CARDOSO, A. S. et al. Intensification: A key strategy to achieve great animal and environmental beef cattle production sustainability in *Brachiaria* grasslands. **Sustainability**, v. 12, n. 16, p. 6656, 2020.

CARNEVALLI, R. A. et al. Growth of *Megathyrus maximus* cv. Mombaça as affected by grazing strategies and environmental seasonality. II. Dynamics of herbage accumulation. **Crop and Pasture Science**, v. 72, n. 1, p. 66-74, 2021.

CARVALHO, D. F. 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, C. R. T. et al. Características agronômicas, massa de forragem e valor nutritivo de *Brachiaria decumbens* em sistema silvipastoril. **Pesquisa Florestal Brasileira**, n. 60, p. 19-19, 2009.

CEN, H.; HE, Y. Theory and application of near infrared reflectance spectroscopy in determination of food quality. **Trends in Food Science & Technology**, v. 18, n. 2, p. 72-83, 2007.

CHERNEY, J. H.; DIGMAN, M. F.; CHERNEY, D. J. Handheld NIRS for forage evaluation. **Computers and Electronics in Agriculture**, v. 190, p. 106469, 2021.

CORRÊA, C. T. R. et al. GISH-based comparative genomic analysis in *Urochloa P. Beauv.* **Molecular Biology Reports**, v. 47, n. 2, p. 887-896, 2020.

CORSON, D. C. et al. NIRS: Forage analysis and livestock feeding. In: **Proceedings of the New Zealand Grassland Association**. 1999. p. 127-132.

COSTA, K. A. P. et al. Efeito da estacionalidade na produção de matéria seca e composição bromatológica da *Brachiaria brizantha* cv. Marandu. **Ciência Animal Brasileira**, Goiânia, v. 6, p. 187-193, 2005.

DANTAS, A. A. A.; CARVALHO, L. G.; FERREIRA, E. Classificação e tendências climáticas em Lavras, MG. **Ciência e Agrotecnologia**, v. 31, p. 1862-1866, 2007.

DEINUM, B.; MAASSEN, A. Effects of drying temperature on chemical composition and in vitro digestibility of forages. **Animal Feed Science and Technology**, v. 46, n. 1-2, p. 75-86, 1994.

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

DIAS, C. S. A. M. M.; NUNES, H. P. B.; BORBA, A. E. S. Influence of the physical properties of samples in the use of nirs to predict the chemical composition and gas production kinetic parameters of corn and grass silages. **Fermentation**, v. 9, n. 5, p. 418, 2023.

DIGMAN, M. F.; CHERNEY, J. H.; CHERNEY, D. JR. The relative performance of a benchtop scanning monochromator and handheld Fourier transform near-infrared reflectance spectrometer in predicting forage nutritive value. **Sensors**, v. 22, n. 2, p. 658, 2022.

FERNANDES, A. M. F. et al. Uso da espectroscopia no infravermelho próximo para previsão da composição químico-bromatológica de palma forrageira. **Revista Agraria Academica**, v. 6, n. 1, p. 25-34, 1 jan. 2023.

FERNÁNDEZ-CABANÁS, V. M. et al. Evaluation of pretreatment strategies for near-infrared spectroscopy calibration development of unground and ground compound feedingstuffs. **Applied Spectroscopy**, v. 60, n. 1, p. 17-23, 2006.

FIDALSKI, J.; TORMENA, C. A.; ALVES, S. J. Intervalo hídrico ótimo de um Latossolo Vermelho distrófico, após o primeiro período de pastejo contínuo de *Brachiaria ruziziensis*, em sistema integração lavoura-pecuária. **Revista Brasileira de Ciência do Solo**, v. 37, p. 775-783, 2013.

FLORINDO, J. B. et al. *Brachiaria* species identification using imaging techniques based on fractal descriptors. **Computers and Electronics in Agriculture**, v. 103, p. 48-54, 2014.

GOBRECHT, A. et al. Combining linear polarization spectroscopy and the Representative Layer Theory to measure the Beer-Lambert law absorbance of highly scattering materials. **Analytica Chimica Acta**, v. 853, p. 486-494, 2015.

GUIMARÃES, I. C. S. B. et al. Assessing the repeatability and reliability of NIRS to predict nutritional values and to evaluate two lignin methods in *Urochloa* spp. grasses. **Grasses**, v. 2, n. 2, p. 112-126, 2023.

HART, L. et al. Comparison of spectral reflectance-based smart farming tools and a conventional approach to determine herbage mass and grass quality on farm. **Remote Sensing**, v. 12, n. 19, p. 3256, 2020.

HOLTSHAUSEN, L. et al. Feeding saponin-containing *Yucca schidigera* and *Quillaja saponaria* to decrease enteric methane production in dairy cows. **Journal of Dairy Science**, v. 92, n. 6, p. 2809-2821, 2009.

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**, v. 270, p. 114674, 2020.

JI, W.; VISCARRA ROSSEL, R. A.; SHI, Z. Accounting for the effects of water and the environment on proximally sensed vis-NIR soil spectra and their calibrations. **European Journal of Soil Science**, v. 66, n. 3, p. 555-565, 2015.

LOPES, F. C. F. et al. Composição química e digestibilidade ruminal in situ da forragem de quatro espécies do gênero *Brachiaria*. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**, v. 62, p. 883-888, 2010.

LOVETT, D. K. et al. Near infrared reflectance spectroscopy (NIRS) to predict biological parameters of maize silage: effects of particle comminution, oven drying temperature and the presence of residual moisture. **Animal Feed Science and Technology**, v. 120, n. 3-4, p. 323-332, 2005.

MEALE, S. J. et al. Methane production of different forages in in vitro ruminal fermentation. **Asian-Australasian Journal of Animal Sciences**, v. 25, n. 1, p. 86, 2012.

MILLER, J.; MILLER, J. C. **Statistics and Chemometrics for Analytical Chemistry**. 7. ed. [S. l.]: Pearson Education, 2018.

MINET, O. et al. Application of NIR spectroscopy to the analysis of forages. In: **Handbook of near-infrared analysis**. CRC Press, p. 583-602, 2021.

MURPHY, D. J. et al. A near infrared spectroscopy calibration for the prediction of fresh grass quality on Irish pastures. **Information Processing in Agriculture**, v. 9, n. 2, p. 243-253, 2022.

OLIVEIRA, B. S. et al. In vitro screening of plants from the Brazilian Caatinga biome for methanogenic potential in ruminant nutrition. **Environmental Science and Pollution Research**, v. 25, p. 35538-35547, 2018.

OLIVEIRA, D. M. et al. Comparative analysis of compact and benchtop near-infrared spectrometers for forage nutritional trait measurements. **Microchemical Journal**, v. 196, p. 109682, 2024.

OTTO, M. **Chemometrics: statistics and computer application in analytical chemistry**. John Wiley & Sons, 2023.

PACIULLO, D. S. C. et al. Morfofisiologia e valor nutritivo do capim-braquiária sob sombreamento natural e a sol pleno. **Pesquisa Agropecuária Brasileira**, v. 42, p. 573-579, 2007.

PAMO, E. T. et al. Nutritive value of some grasses and leguminous tree leaves of the Central region of Africa. **Animal Feed Science and Technology**, v. 135, n. 3-4, p. 273-282, 2007.

PARRINI, S. et al. Near Infrared Spectroscopy technology for prediction of chemical composition of natural fresh pastures. **Journal of Applied Animal Research**, v. 47, n. 1, p. 514-520, 2019.

PASQUINI, C. Near infrared spectroscopy: fundamentals, practical aspects and analytical applications. **Journal of the Brazilian Chemical Society**, v. 14, p. 198-219, 2003.

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

PEIRS, A. et al. Effect of biological variability on the robustness of NIR models for soluble solids content of apples. **Postharvest Biology and Technology**, v. 28, n. 2, p. 269-280, 2003.

REDDERSEN, B.; FRICKE, T.; WACHENDORF, M. 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**, v. 183, n. 3-4, p. 77-85, 2013.

RUKUNDO, I. R. et al. Performance of two handheld NIR spectrometers to quantify crude protein of composite animal forage and feedstuff. **AIMS Agriculture and Food**, v. 6, n. 2, p. 462-477, 2021.

SAHLIN, K. R. et al. An exploration of biodiversity limits to grazing ruminant milk and meat production. **Nature Sustainability**, v. 7, n. 9, p. 1160-1170, 2024.

SANTOS, E. D. G. et al. Avaliação de pastagem diferida de *Brachiaria decumbens* Stapf: 1. Características químico-bromatológicas da forragem durante a seca. **Revista Brasileira de Zootecnia**, v. 33, p. 203-213, 2004.

SANTOS, M. E. R. et al. Características estruturais e índice de tombamento de *Brachiaria decumbens* cv. Basilisk em pastagens diferidas. **Revista Brasileira de Zootecnia**, v. 38, p. 626-634, 2009.

SBRISSIA, A. F.; SILVA, S. C. Compensação tamanho/densidade populacional de perfilhos em pastos de capim-marandu. **Revista Brasileira de Zootecnia**, v. 37, p. 35-47, 2008.

SENA, M. M. et al. Multivariate statistical analysis and chemometrics. In: **Spectroscopic Methods in Food Analysis**. CRC Press, 2017. p. 273-314.

SERRANO, J. et al. Evaluation of near infrared spectroscopy (NIRS) and remote sensing (RS) for estimating pasture quality in Mediterranean Montado ecosystem. **Applied Sciences**, v. 10, n. 13, p. 4463, 2020.

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

SILVA, A. F. et al. Composição florística e grupos ecológicos das espécies de um trecho de floresta semidecídua submontana da Fazenda São Geraldo, Viçosa-MG. **Revista Árvore**, v. 27, p. 311-319, 2003.

SILVA, I. A. G. et al. Tree legume enhances livestock performance in a silvopasture system. **Agronomy Journal**, v. 113, n. 1, p. 358-369, 2021.

SKOOG, D. A.; WEST, D. M.; HOLLER, F. J.; CROUCH, S. R. **Fundamentos de Química Analítica**, Tradução da 8ª Edição norte-americana, Editora Thomson, São Paulo-SP, 2006.

SOARES, A. B. et al. Influência da luminosidade no comportamento de onze espécies forrageiras perenes de verão. **Revista Brasileira de Zootecnia**, v.38, p.443-451, 2009.

SOUSA, L. F. et al. Produtividade e valor nutritivo da *Brachiaria brizantha* cv. Marandu em um sistema silvipastoril. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**, v. 59, p. 1029-1037, 2007.

TESSEMA, B. G. et al. Soil Carbon storage potential of tropical grasses: A review. **Botany-Recent Advances and Applications**, v. 97835, 2021.

THEODOROU, M. K.; WILLIAMS, B.A.; DHANOA, M.S. A simple gas production using a pressure transducer to determine the fermentation kinetics of ruminant feeds. **Animal Feed Science and Technology**, v.48, p.185-197, 1994.

TIAN, W. et al. Rapid determination of total phenolic content of whole wheat flour using near-infrared spectroscopy and chemometrics. **Food Chemistry**, v. 344, p. 128633, 2021.

TORNIAINEN, J. et al. Open-source python module for automated preprocessing of near infrared spectroscopic data. **Analytica Chimica Acta**, v. 1108, p. 1-9, 2020.

TRYGG, J.; HOLMES, E.; LUNDSTEDT, T. Chemometrics in metabonomics. **Journal of Proteome Research**, v. 6, n. 2, p. 469-479, 2007.

TSENKOVA, R. et al. Essentials of aquaphotomics and its chemometrics approaches. **Frontiers in Chemistry**, v. 6, p. 363, 2018.

VAN SOEST, P. J. **The Nutritional Ecology of the Ruminant**. 2. ed. Ithaca: Cornell University Press, 1994.

VARMUZA, K.; FILZMOSER, P. **Introduction to multivariate statistical analysis in chemometrics**. CRC Press, 2016.

WANG, Y.; VELTKAMP, D. J.; KOWALSKI, B. R. Multivariate instrument standardization. **Analytical Chemistry**, v. 63, n. 23, p. 2750-2756, 1991.

WILLIAMS, P.; NORRIS, K. **Near-Infrared Technology in the Agricultural and Food Industries**. 2. ed. Saint Paul: American Association of Cereal Chemists, 2001.

WORKMAN JR, J. J. Interpretive spectroscopy for near infrared. **Applied Spectroscopy Reviews**, v. 31, n. 3, p. 251-320, 1996.

WORKMAN JR, J. J.; WEYER, L. **Practical guide and spectral atlas for interpretive near-infrared spectroscopy**. CRC press, 2012.

YAMADA, W. et al. Handheld Near-Infrared Spectroscopy for Undried Forage Quality Estimation. **Sensors**, v. 24, n. 16, p. 5136, 2024.

YANG, X. et al. Comparative near Infrared (NIR) spectroscopy calibrations performance of dried and undried forage on dry and wet matter bases. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, v. 316, p. 124287, 2024.