



Previsão da composição químico-bromatológica de vagem de algaroba usando a espectroscopia no infravermelho próximo¹. Prediction of the chemical-bromatological composition of mesquite pod using near infrared spectroscopy¹.

[Antônio Marcos Ferreira Fernandes](#)², [Marco Aurélio Delmondes Bomfim](#)³, [Sueli Freitas dos Santos](#)⁴, [Juliete de Lima Gonçalves](#)⁵, [Carlos Mikael Mota](#)⁶

¹ Parte da dissertação de mestrado do primeiro autor. Projeto financiado pela Empresa Brasileira de Pesquisa Agropecuária – Embrapa

² Mestre em Zootecnia - Universidade Estadual Vale do Acaraú, Sobral, Ceará, Brasil. E-mail: marcosff90@gmail.com

³ Pesquisador, Embrapa Caprinos e Ovinos, Sobral, Ceará, Brasil. E-mail: marco.bomfim@embrapa.br

⁴ Pós-Doutora, Embrapa Caprinos e Ovinos, Sobral, Ceará, Brasil. E-mail: sfsantoszootecnia@gmail.com

⁵ Doutora em Zootecnia - Universidade Federal da Paraíba, Areia, Paraíba, Brasil. E-mail: julietegoncalves@gmail.com

⁶ Mestre em Zootecnia - Universidade Estadual Vale do Acaraú, Sobral, Ceará, Brasil. E-mail: carlosmikaell@gmail.com

Resumo

Amostras de vagem de algaroba coletadas no Nordeste brasileiro, foram lidas *in natura* e pré-processadas em NIR Perten® DA 7250 (PerkinElmer, Inc., USA), e pré-processadas em NIR FOSS 5000 Nirsystem II utilizando o software ISIScan®. Análises de referência foram obtidas por metodologias convencionais em laboratório de nutrição animal. Os resultados de referência mostraram boa variação quanto a composição bromatológica. No desempenho dos modelos, aqueles desenvolvidos com pré-processamento da amostra se mostraram mais eficientes do que os construídos com amostras *in natura*. E entre os instrumentos, o Perten apresentou desempenho semelhante ao instrumento FOSS.

Palavras-chave: Alimento alternativo. Análise de alimentos. Caatinga. Suplementação. NIRS.

Abstract

Mesquite pod samples collected in Northeast Brazil were read *in natura* and pre-processed in NIR Perten® DA 7250 (PerkinElmer, Inc., USA), and pre-processed in NIR FOSS 5000 Nirsystem II using ISIScan® software. Reference analyzes were obtained by conventional methodologies in an animal nutrition laboratory. The reference results showed good variation in chemical composition. In the performance of the models, those developed with sample pre-processing were more efficient than those built with *in natura* samples. And among the instruments, Perten performed similarly to the FOSS instrument.

Keywords: Alternative food. Caatinga. Food analysis. Supplementation. NIRS.

Introdução

A suplementação alimentar com alimentos concentrados é a principal estratégia dos produtores para minimizar os efeitos da falta de alimentos durante os períodos de estiagem na região Nordeste do Brasil. Embora, com a especialização dos sistemas de produção, muitos produtores fazem uso desses alimentos durante todo o ano para suprir o aumento das exigências dos animais. Mais de 50% dos produtores de caprinos leiteiros na Paraíba, menos e mais especializados, fazem uso de concentrados durante todo o ano (COSTA; LACERDA; FREITAS, 2010). Porém, a utilização desses alimentos onera a produção devido às flutuações nos preços, principalmente na entressafra, além do mau uso nas dietas dos animais que é feito de forma empírica.

Algumas espécies forrageiras adaptadas às regiões semiáridas são apontadas como soluções para reduzir o impacto negativo na produção animal em períodos de estiagem (VIEIRA et al., 2005). Neste sentido, a vagem de algaroba tem ganhado destaque, o que pode ser comprovado em muitos trabalhos o sucesso de utilização dessa espécie como alimento não convencional. Porém, há a necessidade de análises periódicas da composição química das vagens devido às alterações que essas podem sofrer ao longo do ano. Essa prática, muitas vezes, é negligenciada pelo fato de as metodologias tradicionais despendem de muito tempo e por um custo elevado.

Neste contexto, trabalhos com a espectroscopia na região do infravermelho próximo vêm sendo intensamente desenvolvidos para predição da composição de alimentos. A evolução da computação e desenvolvimento de *software* para tratamentos de dados multivariados contribuíram para esse aumento, tornando a tecnologia NIR uma alternativa economicamente viável e também efetiva às metodologias tradicionais para avaliação da composição dos alimentos. Concomitantemente, houve a preocupação no desenvolvimento de instrumentos mais robustos com baixa sensibilidade a fatores que são considerados críticos na criação de modelos NIR como tamanho de partícula, temperatura e umidade das amostras.

O objetivo deste estudo foi desenvolver e validar modelos de predição da composição bromatológica de vagens de algaroba baseados em espectroscopia NIR e mínimo de quadrados parciais (PLS), escaneados em dois diferentes instrumentos NIRS e com diferentes formas de processamento de amostras.

Material e métodos

Foram coletadas 279 amostras de vagem de algaroba por um período de 12 meses, entre outubro de 2013 e outubro 2014, em propriedades rurais nos estados do Ceará, Paraíba, Pernambuco e junto à empresa Fazendas Reunidas Rio de Contas Ltda - Riocon[®], produtora de rações para alimentação animal localizada no estado da Bahia. As amostras enviadas por essa empresa eram oriundas de cidades da Bahia e de Pernambuco, e estavam armazenadas em galpões por um período entre 4 e 7 meses. Para a realização das análises, as amostras foram encaminhadas ao Laboratório de Nutrição Animal da Embrapa Caprinos e Ovinos, em Sobral, Ceará.

Para coleta dos espectros das amostras *in natura*, as vagens foram fracionadas manualmente (tamanhos aproximados de 1 cm) com a finalidade de padronização do tamanho da amostra. Em seguida as amostras foram lidas em instrumento NIR Perten[®] DA 7250 (PerkinElmer, Inc., USA), o qual registra uma faixa do infravermelho próximo de 950 a 1650 nm, com intervalo espectral de 5 nm. Esse instrumento faz uso de tecnologia de arranjo de diodos, o que comprova a robustez e a precisão desse instrumento, pois não é sensível a vibrações ou temperatura, o que também possibilita a mobilidade desse instrumento para diversos ambientes.

Após a leitura das amostras *in natura*, foi aplicado um pré-tratamento matemático para correção de espalhamento pela técnica MSC (*Multiple Scatter Correction*). Uma técnica multivariada de reconhecimento padrão não supervisionada, chamada de PCA (*Principal Component Analysis*), também foi aplicada para a análise exploratória das amostras, a fim de estabelecer classes ou categorias para a distribuição do conjunto de amostras.

Por meio da ferramenta de seleção “*Evenly Distributed Samples*” do software *The Unscrambler*[®] versão 10.2 (Camo Inc, AS, Norway), foi selecionado um subconjunto amostral de aproximadamente 50% do banco de amostras para realização das análises químicas, usadas como referência para construção dos modelos de calibração, visando reduzir o número de amostras para realização das análises laboratoriais, retirando redundâncias sem prejuízo no desempenho dos modelos. As amostras selecionadas foram pré-secas em estufa de ventilação forçada a 65°C, sendo posteriormente moídas em moinho tipo *Willey* provido de peneira de 1,0 mm de diâmetro e armazenadas em recipientes.

Para obtenção dos espectros das amostras pré-secas e moídas, foram utilizados dois modelos diferentes de aparelhos NIR, Perten[®] DA 7250 NIR, descrito anteriormente, e NIR FOSS 5000 Nirsystem II utilizando o software ISIScan[®], no qual faz leitura numa faixa de 1100 a 2500 nm na região do infravermelho próximo, com intervalo espectral de 2 nm.

Antes de serem lidas novamente, as amostras foram colocadas em envelope de papel e levadas para estufa de ventilação forçada a 65°C por no mínimo três horas para estabilização da umidade. Quando removidas da estufa, foram colocadas em um dessecador por 30 minutos para resfriar até a temperatura ambiente, em seguida colocadas em células e imediatamente destinadas a leitura para obtenção dos espectros das amostras pré-seca e moídas. Os espectros gerados foram arquivados em microcomputador acoplado ao aparelho NIR para uso na geração das equações de predição.

Posteriormente, as amostras selecionadas foram analisadas quanto aos seus teores de matéria seca (MS), matéria mineral (MM) e, por diferença, os teores de matéria orgânica (MO) (AOAC, 2010); nitrogênio total (N) foi determinado em sistema de combustão (Leco FP-628, Leco Corp., St. Joseph, MI, EUA), utilizando-se o fator de correção 6,25 para conversão dos valores de N para proteína bruta (PB); fibra insolúvel em detergente neutro (FDN) e fibra insolúvel em detergente ácido (FDA) segundo descrito por (SENGER et al., 2008); hemicelulose (HEM) por diferença entre os valores de FDN e FDA; extrato etéreo (EE) em extrator semiautomático ANKOM XT-15 (ANKOM Technologic Corp, EUA); digestibilidade *in vitro* da matéria seca (DIVMS) por meio da técnica de duplo estágio descrita por (TILLEY; TERRY, 1963), sendo modificada a quantidade de pepsina utilizada na segunda fase para 2,0 g/L, mantendo-se a mesma concentração de pepsina na solução de digestão, assim como foi estabelecido pelos mesmos autores.

Para as análises quimiométricas foi utilizado o software *The Unscrambler*[®], versão 10.2 (Camo Inc, Oslo, Norway). Com o objetivo de minimizar os efeitos causados por problemas de linha de base devido a dispersão da luz (espalhamento), os espectros foram pré-processados pelo uso de diferentes tratamentos matemáticos e suas combinações: MSC (*multiplicative scatter correction*), SNV (*standard normal variate*), SNV combinado com DT (*De-trending*) ou combinações da correção do espalhamento com a primeira ou segunda derivada, utilizando o método Savitzky-Golay (BROWN; VEGA-MONTOTO; WENTZELL, 2000).

Os modelos de calibração multivariada foram desenvolvimentos usando a Regressão por Mínimos Quadrados (PLS - *Partial Least Squares*). O número de fatores PLS foi determinado pela validação cruzada (*cross-validation*), procedimento “*leave-one-out*” (GELADI; KOWALSKI, 1986), ou seja, todas as amostras utilizadas para calibração, foram também utilizadas para validação dos modelos. Amostras anômalas, conhecidas como outliers, foram retiradas dos modelos por meio de

avaliação de duas grandezas: *leverage* e resíduos de *Student*; sendo considerados como outliers valores elevados de *leverage* e resíduos (CONZEN, 2006; SCHIBORRA et al., 2015).

Os desempenhos dos modelos desenvolvidos foram avaliados de acordo com a raiz do quadrado médio da calibração (RMSEC), e da validação cruzada (RMSECV), o coeficiente de determinação (R^2) dos valores previstos e de referência (WILLIAMS; SOBERING, 1993; WILLIAMS, 2001). Altos valores de R^2 e baixos erros médios (calibração e validação) indicam o melhor modelo para predição.

Foi calculado também a relação de desempenho de desvio dos modelos (*Ratio of Performance to Deviation* – RPD), que representa a divisão entre o desvio padrão da análise de referência e a raiz do quadrado médio da validação cruzada (WILLIAMS, 1987), como apresentado abaixo.

$$RPD = Sd/RMSECV$$

Onde RMSECV = erro médio de validação e Sd = desvio padrão da amostra. Os valores obtidos por essa relação são classificados em três categorias Classe A (RPD > 2,0) – modelos excelentes, com $R^2 > 0,8$; Classe B (RPD de 1,4 a 2,0) – modelos ajustados, com R^2 variando entre 0,5 e 0,8 e Classe C (RPD < 1,4) - modelos não confiáveis, com $R^2 < 0,5$ (CHANG et al., 2001).

Resultados e discussão

Na Figura 1 são exibidos os espectros de 279 amostras de vagem de algaroba, todas escaneadas *in natura*, obtidos numa faixa espectral entre 950 e 1650 nm. Pode ser observada uma variação sistemática no conjunto espectral, apesar desse perfil se manter semelhante. A fim de remover ou reduzir os efeitos causados por essas variações sistemáticas ou ainda, por variações aleatórias que não estejam relacionadas com a composição química da amostra, foi empregado um pré-tratamento matemático chamado MSC (*Multiplicative Signal Correction*). A aplicação dessa ferramenta possibilita também a identificação de possíveis agrupamentos e com isso a seleção de uma região espectral de maior interesse para construção dos modelos de calibração.




Figura 1 - Espectros de 279 amostras de vagem de algaroba sem tratamento (a) e pré-processados usando *Multiple Scatter Correction* – MSC (b) na região de 950 a 1650 nm.

Avaliando-se os espectros pré-tratados com MSC (Figura 1-b), pode ser observada que a semelhança no perfil espectral entre as amostras se manteve e a ocorrência de sobreposições de algumas, o que pode ser um indício de semelhança na composição química entre elas e da complexidade do sinal obtido. Portanto, a avaliação visual dos espectros pré-tratados não possibilitou a identificação de grupos, assim foi aplicada a técnica de reconhecimento padrão não supervisionado PCA (*Principal Component Analysis*) para melhorar a investigação da distribuição das amostras e revelar possíveis agrupamentos.

A Figura 2 mostra os escores do PC-1 (94% da variância explicada) *versus* PC-2 (4% da variância explicada) com a formação de grupos distintos de acordo com a origem das amostras de vagem de algaroba. As amostras de origem do estado da Bahia, em sua grande maioria, ficaram

separadas das demais de procedência dos estados do Ceará, Paraíba e Pernambuco. No entanto, de acordo com os limites estabelecidos por *Hotelling* não foram consideradas significativamente diferentes, possibilitando que essas amostras sejam trabalhadas em um único grupo. É importante lembrar que as amostras da Bahia vieram de galpões de armazenamento em fábricas de rações, que geralmente recebem algum tipo de tratamento para evitar ataques de pragas, e isso pode ser um fator que altere algum componente desse alimento que foi sensível à leitura.




Figura 2 – Gráficos dos escores de PC1 (94%) versus PC2 (4%) das amostras de vagem de algaroba coletadas em diferentes estados: Bahia (BA), Ceará (CE), Paraíba (PB) e Pernambuco (PE). E limites estabelecidos por Hotelling (linha tracejada).

Na Tabela 1 é apresentada a estatística descritiva abrangendo o número de amostras (N); os valores médios, mínimos e máximos; os desvios padrões (DP) e coeficientes de variações (CV) dos parâmetros que foram utilizados como referência para o desenvolvimento dos modelos de calibração.

Tabela 1 – Estatística descritiva dos parâmetros avaliados em amostras de vagem de algaroba

Parâmetros	N	Média (%)	Mín/Máx (%)	DP ¹	CV ² (%)
MS	152	85,15	74,96 - 90,83	3,6	4,22
MO*	152	95,71	87,66 - 98,02	1,62	1,69
MM*	152	4,29	1,98 - 12,34	1,62	37,75
PB*	152	11,57	7,72 - 15,83	1,44	12,46
EE*	145	2,22	0,21 - 4,95	1,18	53,04
FDN*	142	17,13	11,93 - 23,34	1,94	11,34
FDA*	142	15,65	9,82 - 20,75	2,04	13,03
HEM*	142	1,48	0,18 - 3,99	0,62	41,69
DIVMS*	152	67,64	54,51 - 75,93	4,32	6,39

*Em base de matéria seca; ¹Desvio Padrão – DP; ²Coefficiente de Variação – CV; Matéria seca – MS; Matéria orgânica – MO; Matéria mineral – MM; Proteína bruta – PB; Extrato etéreo – EE; Fibra em detergente neutro – FDN; Fibra em detergente ácido – FDA; Hemicelulose – HEM; Digestibilidade *in vitro* da matéria seca – DIVMS.

É importante ressaltar que a composição químico-bromatológica dos alimentos varia em função de alguns fatores inerentes ao próprio alimento e aos tratos culturais. No caso da algaroba, sua composição pode sofrer alteração no solo, uma vez que suas vagens, quando maduras, caem e os animais as consomem; ou como consequência do tratamento que as mesmas recebem em fábricas

de beneficiamento. Todos esses fatores foram levados em consideração para coleta das amostras e isso pode ser observado na variação dos resultados obtidos com as análises químicas das amostras.

Na Tabela 2 são apresentados os melhores modelos de calibração obtidos dos parâmetros avaliados para as amostras de vagem de algaroba.

Para os modelos de calibração de vagem de algaroba *in natura* (Tabela 2), matéria seca (MS) foi o que apresentou o melhor coeficiente de determinação, tanto para calibração, quanto para validação, 0,85 e 0,83%, respectivamente. No entanto, para os demais parâmetros os modelos apresentaram um desempenho menor, com coeficiente de determinação na calibração variando (R^2C) de 0,23 a 0,76%. Este último valor, embora tenha apresentado um bom resultado de coeficiente de determinação, o seu erro médio de validação (RMSECV) foi o mais elevado entre todos os outros (2,79). O baixo desempenho das amostras *in natura* pode estar associado ao elevado conteúdo de água das mesmas. A água é um forte absorvente de radiação no infravermelho, incluindo a região do espectro NIR, principalmente para alimentos com teores de umidade entre 70 e 90% (BÜNING-PFAUE, 2003). No caso da calibração para MS, isso foi um fator positivo, uma vez que a MS do alimento está intimamente relacionada com o conteúdo de água.

Ainda na Tabela 2, são apresentados os resultados das calibrações das amostras vagem de algaroba pré-processada (pré-seca e moída), lidas em dois instrumentos NIR (Pertem® DA 7250 (PerkinElmer, Inc., US) e NIR FOSS 5000 Nirsystem). Nitidamente, há uma melhora substancial no desempenho dos modelos quando comparados com os desenvolvidos com amostras *in natura*. A redução de umidade e a padronização do tamanho de partículas são fatores que influenciam diretamente nos resultados das calibrações (BURNS; CIURCZAK, 2008). A umidade, como foi mostrada anteriormente, absorve radiação na região do infravermelho, limitando assim a compreensão de regiões importantes do espectro NIR. O tamanho de partícula interfere diretamente na difusão da radiação do infravermelho, comprometendo a leitura do espectro. Isso porque, uma superfície que se aproxima do ideal de reflexão difusa pode ser alcançada com a moagem das amostras (BURNS; CIURCZAK, 2008)

Dentre os modelos desenvolvidos para as amostras de vagem de algaroba, em geral, observou-se que os modelos das amostras pré-secas e moídas, analisadas no FOSS foram os mais complexos, variando de 4 a 13. É importante ressaltar, que o número de fatores ou variáveis latentes indica a complexidade do modelo. Quanto mais fatores o modelo utiliza, mais complexo e mais instável ele fica (PASQUINI, 2003).

Para os valores de *Bias* estimados para os modelos (Tabela 2), observou-se que estes foram baixos, variando de 0,0000063 a -0,0000039, concluindo que suas possíveis influências no modelo e nos parâmetros avaliados podem ser desprezíveis.

O desempenho dos modelos avaliados pelo RPD (Tabela 2), para amostras *in natura* (NIR Pertem), modelos desenvolvidos para MS e MM foram classificados como Classe A (modelo de excelência), para os modelos de MO, DIVM e PB como Classe B (modelos ajustados) e os modelos de EE, FDN, FDA e HEM como Classe C (modelos não confiáveis). Já os valores de RPD dos modelos com amostras pré-secas e moídas (NIR Pertem), para MS, MO, MM, PB, FDA e DIVMS foram classificados como Classe A (modelos de excelência), para os modelos de EE, FDN e HEM como Classe B (modelos ajustados). E os modelos com amostras pré-secas e moídas (NIR FOSS) para MS, MO, MM, PB e DIVMS os resultados mostraram classificação em Classe A (modelos de excelência), para os modelos de EE, FDN, FDA e HEM como classe B (modelos ajustados). Esses resultados demonstram que não houve diferença entre os desempenhos dos modelos desenvolvidos para ambos os instrumentos NIR usados neste trabalho. No entanto, o processamento das amostras como tamanho de partícula e umidade foram fatores que influenciaram diretamente no desempenho.

Tabela 2 – Parâmetros estatísticos dos modelos NIRS desenvolvidos para predição da composição da vagem de algaroba

Amostras/aparelho	Parâmetro	N	Tratamentos	Nº Fatores	Bias	Correlação	R ² C	RMSEC	R ² V	RMSECV	RPD
<i>In natura</i> (Perten)	MS	143	SNV+DT	5	2,00E-06	0,92	0,85	1,31	0,83	1,44	2,50
	MO	146	SNV+DT	9	-1,50E-06	0,75	0,56	0,75	0,38	0,89	1,82
	MM	146	SNV+DT/SG2	7	-2,40E-07	0,77	0,6	0,66	0,44	0,79	2,06
	PB	141	SNV/SG1	8	2,30E-07	0,8	0,64	0,75	0,44	0,94	1,54
	EE	130	SNV+DT/SG2	4	-7,80E-08	0,7	0,49	0,81	0,34	0,92	1,28
	FDN	129	ST	7	-9,40E-07	0,54	0,29	1,34	0,15	1,48	1,32
	FDA	130	SNV+DT/SG2	2	-3,70E-08	0,51	0,26	1,48	0,2	1,55	1,31
	HEM	130	SNV/SG1	3	4,30E-08	0,48	0,23	0,43	0,13	0,46	1,35
	DIVMS	133	SNV+DT/SG1	9	1,80E-06	0,87	0,76	1,91	0,53	2,69	1,61
Pré-secas e Moídas (Perten)	MS	140	SNV+DT/SG1	8	2,20E-07	0,94	0,89	1,15	0,82	1,46	2,47
	MO	145	SNV+DT	11	3,20E-07	0,91	0,83	0,53	0,75	0,65	2,47
	MM	147	MSC	11	3,40E-06	0,9	0,81	0,58	0,72	0,71	2,28
	PB	140	SNV+DT/SG1	8	-1,20E-06	0,91	0,82	0,54	0,74	0,66	2,20
	EE	136	MSC/SG2	7	-1,60E-07	0,89	0,8	0,5	0,55	0,75	1,57
	FDN	130	SNV+DT/SG1	7	8,80E-08	0,88	0,78	0,88	0,71	1,01	1,93
	FDA	130	SNV+DT/SG1	9	-3,30E-06	0,91	0,83	0,78	0,73	0,99	2,06
	HEM	128	SNV/SG1	7	3,70E-07	0,69	0,47	0,35	0,26	0,42	1,48
	DIVMS	135	SNV/SG2	5	6,30E-06	0,9	0,8	1,75	0,72	2,11	2,05

Pré-secas e Moídas (Foss)	MS	141	MSC/SG2	4	8,70E-07	0,96	0,91	0,99	0,79	1,54	2,34
	MO	145	MSC/SG1	12	-3,90E-06	0,95	0,91	0,4	0,7	0,72	2,25
	MM	141	MSC/SG1	11	1,30E-07	0,95	0,9	0,39	0,72	0,67	2,52
	PB	138	SG2	12	-5,80E-07	0,96	0,93	0,39	0,79	0,66	2,18
	EE	135	SNV+DT/SG1	13	5,00E-08	0,95	0,91	0,35	0,59	0,75	1,58
	FDN	130	SNV/SG2 1	5	-6,70E-07	0,95	0,9	0,61	0,64	1,16	1,68
	FDA	129	SG2 4	5	1,90E-07	0,94	0,87	0,71	0,66	1,16	1,76
	HEM	131	MSC/SG1 1	13	3,00E-07	0,95	0,91	0,18	0,62	0,37	1,65
	DIVMS	135	SG1 1	10	1,40E-07	0,92	0,84	1,64	0,7	2,04	2,12

Matéria seca – MS; Matéria orgânica – MO; Matéria mineral – MM; Proteína bruta – PB; Extrato etéreo – EE; Fibra em detergente neutro – FDN; Fibra em detergente ácido – FDA; Hemicelulose – HEM; Digestibilidade *in vitro* da matéria seca – DIVMS; Número de amostras – N; MSC - *multiplicative scatter correction*; SNV - *standard normal variate*; SNV+DT - *standard normal variate* combinada *De-trending*; SG1 e SG2 – Derivadas Savitzky-Golay, primeira e segunda derivativa, respectivamente; ST – Sem tratamentos (Espectros originais); R²C – Coeficiente de determinação da Calibração; RMSEC – Erro Médio de Calibração; R²V – Coeficiente de Determinação da Validação; RMSECV – Erro médio de Validação; RPD – Relação de Desempenho de Desvio dos Modelos.

Conclusão

Os modelos desenvolvidos para vagem de algaroba com pré-processamento das amostras, se mostraram mais eficientes do que os construídos com amostras *in natura*. E entre os instrumentos, o NIR Perten apresentou desempenho semelhante ao instrumento NIR FOSS.

Conflitos de interesse

Não houve conflito de interesses dos autores.

Contribuição dos autores

Antônio Marcos Ferreira Fernandes - trabalho da dissertação de mestrado, coleta de dados, interpretação, escrita; Marco Aurélio Delmondes Bomfim - orientador do primeiro autor, ideia original, revisão e correção; Sueli Freitas dos Santos - coleta de dados, revisão e correção; Juliete de Lima Gonçalves - revisão e correção; Carlos Mikael Mota - revisão e correção.

Referências bibliográficas

AOAC. Association of Official Analytical Chemists. **Official Methods of Analysis**. 18th ed. rev. Gaithersburg, Maryland, USA, 2010, 3000p.

BROWN, C. D.; VEGA-MONTOTO, L.; WENTZELL, P. D. Derivative preprocessing and optimal corrections for baseline drift in multivariate calibration. **Applied Spectroscopy**, v. 54, n. 7, p. 1055-1068, 2000. <https://doi.org/10.1366/0003702001950571>

BÜNING-PFAUE, H. Analysis of water in food by near infrared spectroscopy. **Food Chemistry**, v. 82, n. 1, p. 107-115, 2003. [https://doi.org/10.1016/S0308-8146\(02\)00583-6](https://doi.org/10.1016/S0308-8146(02)00583-6)

BURNS, D. A.; CIURCZAK, E. W. **Handbook of Near-Infrared Analysis**. 3rd ed. Boca Raton: CRC, 2008, 808p.

CHANG, C. W.; LAIRD, D. A.; MAUSBACH, M. J.; HURBURGH, C. R. Near-infrared reflectance spectroscopy – principal components regression analysis of soil properties. **Soil Science Society of America Journal**, v. 65, n. 2, p. 480-490, 2001. <https://doi.org/10.2136/sssaj2001.652480x>

CONZEN, J. P. **Multivariate Calibration**. A practical guide for the method development in the analytical chemistry. Ettlingen: Bruker Optick GmbH, 2006.

COSTA, A. R.; LACERDA, C.; FREITAS, F. R. D. A criação de ovinos e caprinos em Campos Sales – CE. **Cadernos de Cultura e Ciência**, v. 2, n. 2, p. 55-63, 2010.

GELADI, P.; KOWALSKI, B. R. Partial least-squares regression: a tutorial. **Analytica Chimica Acta**, v. 185, p. 1-17, 1986. [https://doi.org/10.1016/0003-2670\(86\)80028-9](https://doi.org/10.1016/0003-2670(86)80028-9)

PASQUINI, C. Near infrared spectroscopy: fundamentals, practical aspects and analytical applications. **Journal of the Brazilian Chemical Society**, v. 14, n. 2, p. 198-219, 2003. <https://doi.org/10.1590/S0103-50532003000200006>

SCHIBORRA, A.; BULANG, M.; BERK, A.; SUSENBETH, A.; SCHLECHT, E. Using faecal near-infrared spectroscopy (FNIRS) to estimate nutrient digestibility and chemical composition of diets and faeces of growing pigs. **Animal Feed Science and Technology**, v. 210, p. 234-242, 2015. <https://doi.org/10.1016/j.anifeedsci.2015.10.011>

SENGER, C. C. D.; KOZLOSKI, G. V.; SANCHEZ, L. M. B.; MESQUITA, F. T.; ALVES, T. P.; CASTAGNINO, D. S. Evaluation of autoclave procedures for fiber analysis in forage and concentrate feedstuffs. **Animal Feed Science and Technology**, v. 146, p. 169-174, 2008. <https://doi.org/10.1016/j.anifeedsci.2007.12.008>

TILLEY, J. M. A.; TERRY, R. A. A two-stage technique for the *in vitro* digestion of forage crops. **Grass and Forage Science**, v. 18, n. 2, p. 104-111, 1963. <https://doi.org/10.1111/j.1365-2494.1963.tb00335.x>

VIEIRA, E. L.; CARVALHO, F. F. R.; BATISTA, Â. M. V.; FERREIRA, R. L. C.; SANTOS, M. V. F.; LIRA, M. A.; SILVA, M. J.; SILVA, E. M. B. Composição química de forrageiras e seletividade de bovinos em bosque-de-Sabiá (*Mimosa caesalpiniiifolia* Benth.) nos períodos chuvoso e seco. **Revista Brasileira de Zootecnia**, v. 34, n. 5, p. 1505-1511, 2005. <https://doi.org/10.1590/S1516-35982005000500010>

WILLIAMS, P. C. Implementation of near-infrared technology. In: WILLIAMS, P. C.; NORRIS, K. H. (Eds.). **Near-infrared technology in the agricultural and food industries**. 2nd ed. St. Paul: American Association of Cereal Chemists, Inc., Saint Paul, MN, p. 145-169, 2001.

WILLIAMS, P. C. Variables affecting near-infrared reflectance spectroscopic analysis. In: WILLIAMS, P. C.; NORRIS, K. H. (Eds.). **Near-infrared technology in the agricultural and food industries**. 1st ed. St. Paul: American Association of Cereal Chemists, Inc., Saint Paul, MN, p. 143-167, 1987.

WILLIAMS, P. C.; SOBERING, D. C. Comparison of commercial near infrared transmittance and reflectance instruments for analysis of whole grains and seed. **Journal of Near Infrared Spectroscopy**, v. 1, n. 1, p. 25-33, 1993. <https://doi.org/10.1255/j>

Recebido em 21 de novembro de 2022

Retornado para ajustes em 25 de janeiro de 2023

Recebido com ajustes em 30 de janeiro de 2023

Aceito em 1 de fevereiro de 2023